

РОССИЙСКАЯ НЕЙРОСЕТЕВАЯ АССОЦИАЦИЯ
РОССИЙСКАЯ АКАДЕМИЯ НАУК
МИНИСТЕРСТВО НАУКИ И ВЫСШЕГО ОБРАЗОВАНИЯ РОССИЙСКОЙ ФЕДЕРАЦИИ
МОСКОВСКИЙ ФИЗИКО-ТЕХНИЧЕСКИЙ ИНСТИТУТ
(НАЦИОНАЛЬНЫЙ ИССЛЕДОВАТЕЛЬСКИЙ УНИВЕРСИТЕТ)
ФЕДЕРАЛЬНЫЙ НАУЧНЫЙ ЦЕНТР НАУЧНО-ИССЛЕДОВАТЕЛЬСКИЙ ИНСТИТУТ СИСТЕМНЫХ
ИССЛЕДОВАНИЙ РОССИЙСКОЙ АКАДЕМИИ НАУК
ARTIFICIAL INTELLIGENCE RESEARCH INSTITUTE

XXIV МЕЖДУНАРОДНАЯ НАУЧНО-ТЕХНИЧЕСКАЯ КОНФЕРЕНЦИЯ

НЕЙРОИНФОРМАТИКА-2022

СБОРНИК НАУЧНЫХ ТРУДОВ

- **ТЕОРИЯ НЕЙРОННЫХ СЕТЕЙ, НЕЙРОСЕТЕВЫЕ ПАРАДИГМЫ И АРХИТЕКТУРЫ**
- **НЕЙРОМОРФНЫЕ ВЫЧИСЛЕНИЯ, ГЛУБОКОЕ ОБУЧЕНИЕ**
- **ПРИКЛАДНЫЕ НЕЙРОСЕТЕВЫЕ СИСТЕМЫ**
- **НЕЙРОИНФОРМАТИКА И ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ**
- **АДАПТИВНОЕ ПОВЕДЕНИЕ И ЭВОЛЮЦИОННОЕ МОДЕЛИРОВАНИЕ**
- **НЕЙРОБИОЛОГИЯ И НЕЙРОБИОНИКА**
- **КОГНИТИВНЫЕ НАУКИ И ИНТЕРФЕЙС “МОЗГ-КОМПЬЮТЕР”**

МОСКВА
МФТИ
2022

УДК 001(06)+004.032.26(06)

ББК 72я5+32.818я5

М 82

**XXIV Международная научно-техническая конференция
"НЕЙРОИНФОРМАТИКА-2022" : сборник научных трудов. –
Москва : МФТИ, 2022. – 482 с. : ил.
ISBN 978-5-7417-0823-1**

В сборнике научных трудов представлены доклады XXIV Международной научно-технической конференции «НЕЙРОИНФОРМАТИКА-2022», проходившей 17–21 октября 2022 года в Московском физико-техническом институте (национальном исследовательском университете) (МФТИ).

Тематика конференции охватывает широкий круг вопросов, посвящённых теоретическим и прикладным исследованиям в следующих областях: теория нейронных сетей, нейросетевые парадигмы и архитектуры, нейроморфные вычисления, глубокое обучение, прикладные нейросетевые системы, искусственный интеллект, адаптивное поведение и эволюционное моделирование, нейробиология и нейробионика, когнитивные науки и интерфейс «мозг-компьютер».

Конференция проводилась при поддержке программы «Приоритет 2030».

УДК 001(06)+004.032.26(06)

ББК 72я5+32.818я5

ISBN 978-5-7417-0823-1

© Федеральное государственное автономное образовательное учреждение высшего образования «Московский физико-технический институт (национальный исследовательский университет)», 2022

ОРГАНИЗАТОРЫ КОНФЕРЕНЦИИ

- Российская нейросетевая ассоциация
- Российская академия наук (РАН)
- Министерство науки и высшего образования Российской Федерации (Минобрнауки России)
- Московский физико-технический институт (национальный исследовательский университет) (МФТИ)
- Федеральный научный центр Научно-исследовательский институт системных исследований РАН (НИИСИ РАН)
- Национальный исследовательский ядерный университет «МИФИ» (НИЯУ МИФИ)
- Московский авиационный институт (национальный исследовательский университет), (МАИ)
- AIRI – Научно-исследовательский институт искусственного интеллекта

ОРГАНИЗАЦИОННЫЙ КОМИТЕТ КОНФЕРЕНЦИИ

Председатель – Бурцев Михаил Сергеевич, директор, AIRI – научно-исследовательский институт искусственного интеллекта, Москва; Московский физико-технический институт (национальный исследовательский университет) (МФТИ).

Зам. председателя – Юдин Дмитрий Александрович, Московский физико-технический институт (национальный исследовательский университет) (МФТИ), Москва

Зам. председателя – Климов Валентин Вячеславович, НИЯУ МИФИ, Москва

Акопов Эдмунд Иванович – НИИСИ РАН, Москва

Карандашев Яков Михайлович – НИИСИ РАН, Москва

Киселев Михаил Витальевич – Чувашский государственный университет им. И.Н. Ульянова, Чебоксары

Смирнитская Ирина Аркадьевна – НИИСИ РАН, Москва

Сохова Зарема Борисовна – НИИСИ РАН, Москва

Трофимов Александр Геннадьевич – НИЯУ МИФИ, Москва

Тюменцев Юрий Владимирович – МАИ, Москва

Ученый секретарь – Бесхлебнова Галина Александровна, НИИСИ РАН, Москва

ПРОГРАММНЫЙ КОМИТЕТ КОНФЕРЕНЦИИ

Председатель – чл.-корр. РАН Крыжановский Борис Владимирович, Федеральный научный центр Научно-исследовательский институт системных исследований РАН, Москва

Сопредседатель – Горбань Александр Николаевич, University of Leicester, Great Britain

Зам. председателя – Тюменцев Юрий Владимирович, Московский авиационный институт (национальный исследовательский университет), Москва

Зам. председателя – Редько Владимир Георгиевич, Федеральный научный центр Научно-исследовательский институт системных исследований РАН, Москва

Члены Программного комитета

Golovko Vladimir Adamovich

Brest State Technical University, Belarus

Prokhorov Danil Valentinovich

Toyota Research Institute of North America, USA

Академик РАН Анохин Константин Владимирович
Институт перспективных исследований мозга МГУ им. М.В. Ломоносова, Москва
Бурцев Михаил Сергеевич
AIRI – Научно-исследовательский институт искусственного интеллекта, Москва
Московский физико-технический институт (национальный исследовательский университет), Москва
Введенский Виктор Львович
Национальный исследовательский центр «Курчатовский институт», Москва
Горбань Александр Николаевич
University of Leicester, Great Britain
Доленко Сергей Анатольевич
НИИ ядерной физики им. Д.В. Скобельцына МГУ им. М.В. Ломоносова, Москва
Дудкин Александр Арсентьевич
Объединенный институт проблем информатики Национальной академии наук
Беларуси, Минск
Дунин-Барковский Виталий Львович
Московский физико-технический институт (национальный исследовательский университет), Москва
Ежов Александр Александрович
Государственный научный центр Российской Федерации Троицкий институт
инновационных и термоядерных исследований (ГНЦ РФ ТРИНИТИ), Москва
Каганов Юрий Тихонович
Московский государственный технический университет им. Н.Э. Баумана, Москва
Казанович Яков Борисович
Институт математических проблем биологии РАН – филиал Института приклад-
ной математики им. М.В. Келдыша РАН, Московская область, Пушкино
Литинский Леонид Борисович – Федеральный научный центр
Научно-исследовательский институт системных исследований РАН, Москва
Макаренко Николай Григорьевич
Главная (Пулковская) астрономическая обсерватория РАН, Санкт-Петербург
Мишулина Ольга Александровна
Национальный исследовательский ядерный университет «МИФИ», Москва
Панов Александр Игоревич
Федеральный исследовательский центр "Информатика и управление" РАН,
Москва
Самсонович Алексей Владимирович
Национальный исследовательский ядерный университет «МИФИ», Москва
Терехов Сергей Александрович
Российская нейросетевая ассоциация, Москва,
Российская ассоциация искусственного интеллекта (РАИИ), Москва

Трофимов Александр Геннадьевич

Национальный исследовательский ядерный университет «МИФИ», Москва

Ушаков Вадим Леонидович

Институт перспективных исследований мозга МГУ им. М.В. Ломоносова, Москва

Чижов Антон Вадимович

Физико-технический институт им. А.Ф. Иоффе РАН, Санкт-Петербург

Шумский Сергей Александрович

Московский физико-технический институт (национальный исследовательский университет), Москва

Юдин Дмитрий Александрович

Московский физико-технический институт (национальный исследовательский университет), Москва

Яхно Владимир Григорьевич

Институт прикладной физики РАН, Нижний Новгород

Уважаемые коллеги!

Конференция НЕЙРОИНФОРМАТИКА вновь собирает исследователей, работающих по актуальным направлениям теории и приложений искусственных нейронных сетей. Как и на предыдущих наших собраниях, в этом году на конференции «НЕЙРОИНФОРМАТИКА-2022» представлены доклады по проблемам теории нейронных сетей, нейробиологии, моделям адаптивного поведения, прикладным задачам нейроинформатики.

Более 200 российских ученых и наших зарубежных коллег представляют на конференции результаты своих исследований.

По сложившейся традиции конференцию открывают доклады приглашенных участников. В рамках школы-семинара участники конференции прослушают лекции известных специалистов по актуальным проблемам нейроинформатики. На мастер-классах от ведущих компаний можно познакомиться с различными приложениями искусственных нейронных сетей.

Особое внимание уделяется работам студентов, аспирантов и молодых специалистов, которые примут участие в творческом конкурсе.

За прошедшие годы научно-техническая конференция «НЕЙРОИНФОРМАТИКА» сложилась как представительный и многоплановый по тематике научный форум, в работе которого принимают участие и известные ученые, и молодые специалисты, аспиранты и студенты.

Желаем всем участникам конференции плодотворной работы, активного сотрудничества и новых творческих идей!

СОДЕРЖАНИЕ

ТЕОРИЯ НЕЙРОННЫХ СЕТЕЙ, НЕЙРОСЕТЕВЫЕ ПАРАДИГМЫ И АРХИТЕКТУРЫ.....	14
АНЦИПЕРОВ В.Е., ПАВЛЮКОВА Е.Р.	
Нейроморфное кодирование изображений на основе разбиения выборки отсчетов системой рецептивных полей	14
ДОРОГОВ А.Ю.	
Применение быстрых нейронных сетей для корреляционных измерений	25
КАРАНДАШЕВ Я.М., МИХАЛЬЧЕНКО Е.В., МАЛЬСАГОВ М.Ю., НИКИТИН В.Ф.	
Аппроксимация химической кинетики искусственной нейронной сетью	37
КРЫЖАНОВСКИЙ Б.В., ЛИТИНСКИЙ Л.Б., КАГАНОВА И.М.	
Термодинамика взаимодействия двух однородных групп бинарных агентов.....	46
НЕЙРОМОРФНЫЕ ВЫЧИСЛЕНИЯ, ГЛУБОКОЕ ОБУЧЕНИЕ	55
АНТОНОВ Д.И., СУХОВ С.В.	
Механизмы предотвращения катастрофического забывания в импульсных нейронных сетях.....	55
КРАСНИКОВ В.В., ЧЕЖЕГОВ А.А., БАЛАШОВ И.С., ЧИЖОВ А.С., ГРУНИН А.А., ФЕДЯНИН А.А.	
Нейроморфные фотоэлектрические синапсы на основе нанокристаллитов оксидов металлов	65
КРАСНОВ М.М., СМОЛИН В.С.	
Использование дифференциальных свойств для повышения качества аппроксимации функций нейросетями.....	68
ЧАПЛИНСКАЯ Н.В.	
Обучение спайковой нейронной сети на основе изменения временных задержек на синапсах	78

ШАМИН А.Ю., КАРАНДАШЕВ Я.М.

Нейросетевой метод решения дифференциальных уравнений
с различными начальными значениями 88

ПРИКЛАДНЫЕ НЕЙРОСЕТЕВЫЕ СИСТЕМЫ 97

БАРИНОВ Р.О., ГАЙ В.Е., ПОЛЯКОВ И.В., КУЗНЕЦОВ Г.Д.,
ТИЩЕНКО А.А.

Модель и алгоритмы автоматической оценки результатов обучения
нейронной сети 97

BRYKIN G.S.

Deoldify.net: cross-platform application for coloring black and white
photos 107

ГАБДРАХМАНОВА Н.Т., ПИЛЬГУН М.А.

Свёрточные нейронные сети в задачах оценки и прогнозирования
развития ситуации по цифровым данным 116

ДУДКИН А.А., ГАНЧЕНКО В.В., ИНЮТИН А.В., МАРУШКО Е.Е.

Нейросетевая модель классификации, основанная на использовании
автоэнкодера и построенная по архитектуре ансамбля
многослойных персептронов 127

ТЕРЕХОВ В.И., ИШКОВ Д.О.

Поиск нейросетевой архитектуры для решения задачи
аппроксимации метода динамического анаморфирования 137

КАРИМОВ Э.З., ШИРОКИЙ В.Р., МЯГКОВА И.Н.

Применение методов машинного обучения для доменной
адаптации данных космических аппаратов 146

ЛИТИНСКИЙ Л.Б.

Опыт обработки спектрограмм выдоха для пробной группы
пациентов методом главных компонент 155

ЛОБАНОВ А.В., ЛАЗАРЕВА Г.Г.

Первичная подготовка данных для анализа снимков МСКТ головного
мозга для задачи поиска первичных признаков инсульта головного
мозга 164

МАКАРОВ М.В., СЕМЕНОВ И.А., ДЕМИДОВ А.А.,
ТРАНТИНА Н.С.

Исследование нового типа эвристических решений для адаптивного
управления мобильным роботом в динамической среде174

НУЖНЫЙ А.С., ЛЕВЧЕНКО Е.Н., ГЛУХОВ А.Ю.

Построение нейросетевой модели оптимального управления
процессами нефтепереработки184

СОБЯНИН К.В., РУСАКОВА Е.И.

Применения комбинированных функции потерь и метрики
при обучении U-Net в задаче семантической сегментации очага ОМНК
.....194

СТАРОВЕРОВ Б.А., ОЛОНICHEВ В.В., ТАРАСОВ С.Д.

Нейросетевые последовательные методы параметрической
идентификации динамических процессов203

SYSOYKIN E.M., SHPAK I.D., ANTONOV A.I.

Competition number recognition using an ensemble of deep learning
models213

ЧЕРНЫШЕВ Л.С.

Прогнозирование значений временного ряда с помощью нейронной
сети при решении задачи динамического ценообразования221

ШИБЗУХОВ З.М.

Об одном обобщенном нейросетевом методе кластерной регрессии ..232

ENGEL E.A., ENGEL N.E.

The intelligent times series forecasting framework.....240

НЕЙРОИНФОРМАТИКА И ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ ...251

ZAYTSEV E.I., NURMATOVA E.V.

On the organization of the multi-agent knowledge representation
and processing system.....251

КУРЬЯН В.Е.

Моделирование процесса обучения человека. Аксиоматический
подход260

САМАРИНА А.И., КОРЧИГИН А.А.

Автоматизация гистологических исследований для выявления
ранней онкологической патологии груди270

СЕРЕДА Я.А., НИКОНОВ И.Д., ПРЕОБРАЖЕНСКАЯ Ю.Д.

Модель обучения агента, основанная на заполнении когнитивной
карты279

СМОЛИН В.С., ЖУРАВЛЕВ Д.В.

Теории познания, сознания, эмоций и прочих «человеческих»
свойств для роботов288

АДАПТИВНОЕ ПОВЕДЕНИЕ И ЭВОЛЮЦИОННОЕ МОДЕЛИРОВАНИЕ299

ПОЛЕВАЯ С.А., САВЧУК Л.В., ГРОМОВ К.Н., ФЕДОТЧЕВ А.И.,
ПАРИН С.Б.

Отображение школьной дезадаптации в режимах вегетативной
регуляции299

EL-KHATIB SAMER, SKOBTISOV Yu.A., RODZIN S.I.

Optimal number of ants determination in image segmentation method
for complexly structured images307

ТИХОНОВ И.В., ЖДАНОВ А.А.

Адаптивный алгоритм трекинга задач реального времени315

НЕЙРОБИОЛОГИЯ И НЕЙРОБИОНИКА325

BOZHOKIN S.V.

Neurocardiology: wavelet analysis of heart rate turbulence325

ВОРОНКОВ Г.С.

Неизвестная характеристика феномена «Куб Неккера»: два 3d-образа
куба зеркальны друг другу333

ЛЯХОВЕЦКИЙ В.А., МОРОЗОВ Д.Д., МУСИЕНКО П.Е.,
МЕРКУЛЬЕВА Н.С.

Нелинейная динамическая модель системы генераторов ритма
шагания343

МАЙОРОВ В.И.

ABCD нейроморфного интеллекта351

МАЙОРОВ В.И.

Функции дофамина в обучении с подкреплением361

НАЖЕСТКИН И.А.

Приближённые методы вычисления коэффициента интегрированной информации для исследования пластичности нейронных сетей головного мозга при обучении371

ТИТОВ В.Е., ДИК О.Е.

Частотный анализ на основе синхросжатого вейвлет-преобразования ритмов мозга и сердца при сосудистой патологии мозга381

КОГНИТИВНЫЕ НАУКИ И ИНТЕРФЕЙС

“МОЗГ-КОМПЬЮТЕР”391

АФОНИН А.Н., ГЛАДЫШЕВ А.Р., ГЛАДЫШЕВА А.В.

Система управления бионического протеза кисти руки на основе адаптивного неинвазивного анализатора мышечной активности391

ГАНЕЕВА В.А., КЛЫШИНСКИЙ Э.С.

Исследование интерпретационных свойств статических векторных моделей для русского языка401

DEMICHEVA A.A., KORSAKOV A.M., BAKHSHIEV A.V.

Pain sensation model based on the compartment spiking neuron model (CSNM).....411

КАПУСТНИКОВ А.А., СЫСОЕВ И.В., СЫСОЕВА М.В.

Моделирование эпилепсии с использованием специализированных нейронов разных типов.....419

ПОЛЕВАЯ А.В., ПОЛЕВАЯ С.А., ПЕТУХОВ А.Ю., ЛОСКОТ И.В., ПАРИН С.Б.

Экспериментальная диагностика эмоционального состояния индивидов с использованием аффективных аудиовизуальных стимулов424

ПУГАВКО М.М., МАСЛЕННИКОВ О.В., НЕКОРКИН В.И.

Динамика рекуррентной спайковой нейронной сети при решении
нескольких задач когнитивной нейронауки433

САМСОНОВИЧ А.В.

О возможности определения психологических характеристик
личности пользователя при его рутинном взаимодействии
с артефактом444

СЕЛЕЗНЕВ Л.Е., ЧУПАХИН А.А., КОСТЕНКО В.А., ВАРТАНОВ А.В.,
ШЕВЧЕНКО А.О.

Распознавание мысленно произносимых фонем с использованием
свёрточных нейронных сетей на основании данных
электроэнцефалографии454

СЕРГИН В.Я.

Природа и нейронные механизмы сознания463

ШАЦ В.Н.

Аппроксимация структуры данных в задаче классификации473

ТЕОРИЯ НЕЙРОННЫХ СЕТЕЙ, НЕЙРОСЕТЕВЫЕ ПАРАДИГМЫ И АРХИТЕКТУРЫ

В.Е. АНЦИПЕРОВ, Е.Р. ПАВЛЮКОВА

Институт радиотехники и электроники им. В. А. Котельникова РАН
anticiperv@cplire.ru

НЕЙРОМОРФНОЕ КОДИРОВАНИЕ ИЗОБРАЖЕНИЙ НА ОСНОВЕ РАЗБИЕНИЯ ВЫБОРКИ ОТСЧЕТОВ СИСТЕМОЙ РЕЦЕПТИВНЫХ ПОЛЕЙ*

Рассматривается проблема синтеза методов кодирования изображений на основе данных самих изображений. Предлагаемый подход основан на разработанном ранее специальном представлении изображений выборками отсчетов (выборочными представлениями). Поскольку выборочные представления являются по существу случайными конструкциями, синтез методов кодирования осуществляется строго в рамках генеративного подхода. В рамках данного подхода процедура кодирования изображений трактуется как частный случай статистического параметрического оценивания плотности распределения вероятностей. Выбор параметрического семейства возможных распределений ограничен в работе моделью смеси предопределенных компонент. Соответственно, набор оценок весов компонент смеси, рассчитанный по выборочному представлению, рассматриваемому как входные данные, интерпретируется как код изображения – выходные данные. В этом контексте естественным критерием оптимального кодирования является критерий максимального правдоподобия. Для алгоритмической реализации процедуры кодирования модель смеси оснащена структурой рецептивных полей, известной в нейрофизиологии как основной принцип организации рецепторов сетчатки глаза человека. На этой основе синтезирован относительно простой алгоритм рекуррентного кодирования, близкий к популярному в машинном обучении ЕМ-алгоритму. В статье представлена интерпретация некоторых особенностей алгоритма с точки зрения известных фактов об обработке изображений в периферии зрительной системы, обсуждаются варианты реализации алгоритма и представлены результаты численного моделирования его работы.

*Работа выполнена за счет бюджетного финансирования в рамках государственного задания в ИРЭ им. В.А. Котельникова РАН (ГЗ “РЭЛДИС”).

Ключевые слова: *нейроморфное кодирование, выборочные представления, рецептивные поля, оценивание плотности распределения.*

Введение

Принципы преобразования, регистрации и обработки светового потока в зрительной системе человека и высших позвоночных воспроизводятся искусственными видеосистемами с момента изобретения фотографии. В процессе развития фотокамер от простейшей камеры-обскуры до современных цифровых камер количество заимствованных принципов только увеличивалось. Примерами являются: диафрагма как аналог способного к аккомодации зрачка глаза, система фокусирующих линз, имитирующая хрусталик, регистрирующие свет элементы в виде пластин с фотоэмульсией зерен галогенида серебра или в виде ПЗС/КМОП-матриц, моделирующих сетчатку со множеством мелких фоторецепторов.

В этой связи следует отметить, что наиболее глубокой эволюции подверглись именно элементы регистрации изображения: от дагерротипов, обработанных парами ртути посеребренных медных пластин (1837 г.), через их прямых наследников – целлулоидных фотопластинок с желатиново-серебряной эмульсией, открывающих век аналоговой фотографии (XX век), к веку цифровой фотографии на основе матриц полупроводниковых фотодиодов (XXI век). Появление последних связано с изобретением устройств с зарядовой связью (ПЗС) в 1969 году и последующим изобретением светочувствительных матриц на основе комплементарных структур металл-оксид-проводник (КМОП). В 1993 году была представлена первая КМОП-матрица с активными пикселями [1]. Переход от аналоговой фотографии к цифровой позволил значительно улучшить практически все параметры видеосистем, среди которых: увеличение пространственного разрешения, снижение энергопотребления, сокращение времени экспозиции и др.

С переходом на цифровые устройства появилась возможность управлять размерами отдельных регистрирующих элементов видеоматриц – джотов, искусственных аналогов фоторецепторов сетчатки. На сегодняшний день анонсирован выпуск матрицы на 41 МБ с шагом пикселя 2,2 мкм, работающей с частотой 30 кадров в секунду [2]. Учитывая, что человеческий глаз содержит ~100 миллионов рецепторов размерами 2,5–5 мкм, становится ясно, что современные видеосистемы если уже не достигли характеристик сетчатки, то вплотную приблизились к ним. Отметим, что при размерах джотов ~1 мкм механизмы регистрации излуче-

ния приобретают выраженный квантовый характер, что допускает работу видеоматриц в так называемом *режиме счета фотонов*. Последнее обстоятельство открывает принципиально новые возможности для систем визуализации и ставит новые задачи в области формирования изображений [1].

Однако важнейшим преимуществом цифровых устройств, обеспечившим им безоговорочную победу над аналогами, является способность преобразовывать регистрируемое световое излучение непосредственно в выходной электрический ток. Фототок регистрации без промежуточного накопления, фиксации и сохранения может быть передан напрямую в следующие за видеоматрицей электрические схемы, содержащие, как правило, микропроцессоры. Вычислительная мощность современных микропроцессоров позволяет решать не только стандартный набор задач предварительной обработки видеосигнала, таких как компенсация бликов, коррекция темнового тока, баланс белого тона и т. д., но и выполнять гораздо более сложные процедуры обработки изображений, подобные происходящим в центральной зрительной системе человека.

Среди наиболее эффективных процедур обработки цифровых изображений отметим в первую очередь методы машинного обучения (МО). За последнее десятилетие методы МО, в особенности, связанные с нейронными сетями, достигли выдающихся результатов [3]. Наиболее впечатляющими приложениями МО в области обработки изображений являются распознавание рукописного текста, текстовое описание изображений, распознавание лиц/объектов на изображениях и т. д. При этом, как это ни парадоксально, основания достигнутых результатов не совсем понятны – достигнутые, как правило, экспериментально, они до сих пор не имеют убедительного теоретического обоснования. Что можно сказать с уверенностью, так это то, что успехи связаны с более адекватным моделированием механизмов естественного (человеческого) интеллекта [3].

Поскольку основной особенностью подхода МО является ориентация на данные, характеристики различных методов МО определяются, во-первых, типом обучающих данных (типом обучения), а во-вторых, типом модели (разметки) данных. Тип обучающих данных подразумевает наличие или отсутствие в них явной разметки. Это ведет к разделению методов машинного обучения на обучение с учителем и без учителя. Тип используемой модели, связывающей данные с разметкой, зависит от того, основана ли модель на условной вероятности разметки по отношению к данным или на их совместном распределении [4]. По типу модели методы машинного обучения делятся соответственно на *дискриминантные* и *ге-*

неративные. Полученный к настоящему времени опыт говорит о том, что подходы, основанные на генеративных моделях обучения без учителя, более успешны со многих точек зрения. Отметим здесь генеративно-состязательные сети, вариационные автоэнкодеры, сети глубокого доверия и т. д.

Причина успеха генеративных моделей без учителя также до конца не понятна. Однако все чаще отмечается, что она, вероятно, более тесно связана с отмеченной тенденцией в МО ко всё более адекватному моделированию функций (интеллекта) головного мозга. В этой связи возникает следующая проблема: каким образом с помощью допустимых компьютерных структур данных можно было бы наиболее оптимально смоделировать, представить соответствующие функции/структуры неокортекса? Эта проблема имеет также следующий технический аспект: в какой мере выбор (компьютерного) представления данных может предопределить синтез ожидаемых функций? Другими словами, в какой степени выбор представления данных может предопределить эффективность методов МО, подобно тому, как в середине 80-х объектно-ориентированный подход коренным образом изменил методы создания программного обеспечения [5]?

В данной работе сделана попытка частичного ответа на поставленные вопросы. Мы предлагаем новый подход к конкретной проблеме машинного обучения – проблеме синтеза методов кодирования изображений на основе данных самих изображений. Предлагаемый подход основан на разработанном ранее специальном представлении изображений (входных данных) с использованием выборок отсчетов (выборочных представлений) [6, 7]. Поскольку для представлений выборки полное статистическое описание факторизуется в произведение плотностей распределения вероятностей ее отдельных отсчетов, предлагаемый подход основан по существу на классической задаче оценки этих плотностей [8]. Ограничивая выбор процедур оценивания классом методов параметрического оценивания [8], синтез кодирования изображений фокусируется на моделях параметрических смесей заданных компонент распределений [9]. Соответственно набор оценок весов компонент, вычисленных по выборочному представлению (входные данные), рассматривается как закодированное изображение (выходные данные). В данном контексте оптимальное кодирование синтезируется на основе метода максимального правдоподобия [10]. Для алгоритмической (компьютерной) реализации процедуры кодирования используется модель смеси, компоненты которой представляют покрывающую изображение систему рецептивных полей.

Представление изображений выборками отсчетов

Мотивацию предлагаемого ниже представления изображений можно получить, сопоставляя естественную систему регистрации излучения – сетчатку глаза и ее искусственные аналоги – в виде КМОП-видеоматриц. Все эти системы имеют светочувствительную поверхность, содержащую большое количество рецепторов/фотодетекторов. Последние могут регистрировать одиночные фотоны падающего излучения интенсивности $I(\vec{x})$, где $\vec{x}$ – координаты на поверхности. Эти системы могут обрабатывать события, связанные с регистрацией фотонов в течение некоторого промежутка времени (кадра). События эти обычно называются *фотоотсчётами*, или просто *отсчётами*. Результаты предварительной обработки системами отсчетов могут быть переданы в последующие блоки анализа / интерпретации зарегистрированных данных в виде некоторого цифрового кода (нейроимпульсов в случае сетчатки, данных АЦП в случае видеоматриц).

В предшествовавших работах [6, 7], исходя из перечисленных выше свойств, была предложена формальная концепция идеальной видеосистемы, под которой понимается плоская 2D-область Ω , на которой вплотную друг к другу расположены одинаковые точечные детекторы, или джоты в терминологии [1]. Точечные детекторы по определению имеют светочувствительные поверхности очень маленькой площади ds . Соответственно общее количество детекторов есть $N = S/ds$, где S – общая площадь поверхности Ω . В предположении, что S фиксировано и $ds \rightarrow 0$, число N считается очень большим: $N \rightarrow \infty$. Таким образом, идеальная видеосистема представляет собой почти непрерывную чувствительную область Ω , координаты $\vec{x} = (x_1, x_2)$ на которой определяют положение идеальных точечных детекторов и могут кодировать соответствующие отсчеты.

Основываясь на концепции идеальной видеосистемы, можно определить модель идеального изображения. Под идеальным изображением понимается (упорядоченное) множество $X = (\vec{x}_1, \dots, \vec{x}_n)$ всех n случайных отсчетов, зарегистрированных точечными детекторами идеальной видеосистемы за время кадра T при регистрации (детерминированного) излучения интенсивности $I(\vec{x})$. Таким образом, идеальное изображение есть принципиально случайный объект и его случайный характер обусловлен фундаментальными свойствами квантовых процессов взаимодействия излучения с веществом. Отметим, что случайность идеального изображения выражается не только случайными координатами $\vec{x}_i$ отсчетов, но и их случайным общим числом n (размером X).

Полное статистическое описание идеального изображения в виде набора всех многомерных плотностей распределения $\{\rho(\vec{x}_1, \dots, \vec{x}_n, n|I(\vec{x}))\}$ можно получить, предполагая условную независимость (при заданной интенсивности $I(\vec{x})$) отсчетов $\vec{x}_i$. Подробный статистический вывод этого описания представлен в [6]. Приведём здесь только результат, заключающийся в том, что множество отсчетов $X = (\vec{x}_1, \dots, \vec{x}_n)$ описывается на Ω двумерным точечным процессом Пуассона, интенсивность которого $\bar{n}(\vec{x})$ (среднее число отсчетов на единицу площади) с точностью до множителя αT совпадает с интенсивностью $I(\vec{x})$ зарегистрированного излучения:

$$\rho(\vec{x}_1, \dots, \vec{x}_n, n|I(\vec{x})) = \rho(\vec{x}_1, \dots, \vec{x}_n, |n, I(\vec{x})) \times P_n(I(\vec{x})) = \prod_{i=1}^n \rho(\vec{x}_i|I(\vec{x})) \times P_n, \quad (1)$$

$$P_n = \frac{\bar{n}^n}{n!} \exp(-\bar{n}), \quad \bar{n} = \iint_{\Omega} \bar{n}(\vec{x}) ds = \alpha T \iint_{\Omega} I(\vec{x}) ds,$$

где плотность единичного отсчета $\rho(\vec{x}_i|I(\vec{x}))$ задается посредством:

$$\rho(\vec{x}_j|I(\vec{x})) = \frac{\bar{n}(\vec{x}_j)}{\bar{n}} = \frac{I(\vec{x}_j)}{\iint_{\Omega} I(\vec{x}) ds}. \quad (2)$$

В приведенных выражениях параметр $\alpha = \eta(h\bar{\nu})^{-1}$ зависит от $h\bar{\nu}$ – средней энергии регистрируемых фотонов (h – постоянная Планка, $\bar{\nu}$ – характерная частота излучения) и от безразмерного коэффициента η – квантовой эффективности детекторов. Обоснование этих соотношений, основанное на современной (квантовой) физике, можно найти в [11].

Модель идеального изображения и его статистическое описание (1–2), очевидно, не являются оригинальными – они давно используются при малых интенсивностях $I(\vec{x})$ регистрируемого излучения, например, в областях флуоресцентной микроскопии, позитронной эмиссионной томографии (ПЭТ), однофотонной эмиссионной компьютерной томографии (ОФЭКТ) и др. Однако в обычных условиях практическое использование модели идеального изображения оказывается проблематичным. Дело в том, что потоки фотонов, например, в ясный день от солнца огромны – они составляют $\sim 10^{15}$ – 10^{16} фотонов/мм² в с. Для реальных видеосистем, работающих в режиме счета фотонов, работа с такими потоками данных потребует слишком много ресурсов. Поэтому желательно адаптировать идеальную модель изображения к реальным практическим условиям. Некоторое время назад нами было предложено следующее решение проблемы [6, 7]. Зафиксируем с самого начала некоторый приемлемый размер представления $k \ll \bar{n}$ и, рассматривая идеальное изображение $X = (\vec{x}_1, \dots, \vec{x}_n)$ как некоторую генеральную совокупность случайных от-

счетов, выберем из нее в полном соответствии с подходом классической статистической теории случайную выборку в k отсчетов $X_k = (\vec{x}_{j_1}, \dots, \vec{x}_{j_k})$. Очевидно, что эта выборка X_k , имея меньший размер, все же представляет исходное (идеальное) изображение X . Поэтому X_k действительно представляет изображение и по этой причине была названа представлением изображения выборкой случайных отсчетов или, короче, *выборочным представлением*. Статистическое описание выборочного представления $X = (\vec{x}_1, \dots, \vec{x}_n)$ выводится из (1, 2) (см. [6]) и имеет следующий вид:

$$\rho(X_k|I(\vec{x})) = \prod_{j=1}^k \rho(\vec{x}_{j_k}|I(\vec{x})),$$

$$\rho(\vec{x}_{j_k}|I(\vec{x})) = \frac{I(\vec{x}_{j_k})}{\iint_{\Omega} I(\vec{x}) ds}, \quad (3)$$

где индексация отсчетов $\vec{x}_j$ заменена на внутреннюю в представлении X_k .

Статистическое описание (3) для выборочного представления $X_k = (\vec{x}_1, \dots, \vec{x}_n)$ обладает рядом замечательных свойств с точки зрения его последующего статистического анализа. Во-первых, (3) фиксирует условную независимость и одинаковое распределение (свойство *iid*) всех k отсчетов представления. Во-вторых, плотность распределения каждого из отсчетов $\rho(\vec{x}_{j_k}|I(\vec{x}))$ связана с интенсивностью регистрируемого излучения $I(\vec{x})$ очень простым образом – она равна нормированной интенсивности. И, в-третьих, описание (3) является в определенном смысле универсальным – оно не зависит ни от деталей механизма регистрации, а именно от квантовой эффективности η , ни от спектра регистрируемого излучения $\bar{\nu}$, т от времени фрейма T . Эти свойства характеризуют выборочные представления как чрезвычайно удобную форму представления входных данных для многих хорошо разработанных и проверенных методов МО.

Кодирование изображений системой рецептивных полей

Используем предложенные выборочные представления для решения одной из важнейших задач в области обработки изображений – задачи синтеза методов кодирования. Синтез кодирования изображений, что в широком смысле подразумевает их сжатие, обычно осуществляется на одной из двух платформ: устранение избыточности в исходном изображении или оптимальное векторное квантование изображений, соответствующее наилучшему воспринимаемому (перцептивному) качеству. В данной работе, ориентированной на моделирование механизмов зрительной системы, за основу взят второй подход – синтез оптимальных методов перцептивного кодирования [12]. Основное отличие перцептивного коди-

рования от традиционных кодеров, уменьшающих избыточность в изображениях, связано с выбором метрики подобия кодируемых и декодируемых изображений [12].

Для обоснования предложенной ниже перцептивной метрики кодирования изображений опишем кратко известные факты зрительного восприятия (в основном касающиеся периферии зрительной системы – сетчатки) [13]. Сетчатка глаза организована слоями. В наружном слое находятся фоторецепторные клетки – палочки и колбочки, которые под действием падающего света активируют биполярные клетки, лежащие в среднем слое. Биполярные клетки передают сигналы рецепторов ганглиозным клеткам, расположенным во внутреннем слое. Ганглиозные клетки, единственные из всех нейронов сетчатки, способные генерировать потенциал действия, в ответ на полученные сигналы формируют нервные импульсы и передают их по собранным в зрительный нерв аксонам в центральную зрительную систему (головной мозг). Здесь важно отметить, что в большинстве случаев нервные импульсы, посылаемые в мозг, не являются непосредственно регистрируемыми отсчетами фоторецепторов, а формируются на их основе с помощью многочисленных промежуточных нейронов среднего и внутреннего слоев. В результате ганглиозные клетки получают сигналы от десятков, а иногда и тысяч рецепторов, расположенных в небольших участках сетчатки, получивших название рецептивных полей (РП) [13]. С их помощью реализуются определенные механизмы первичной обработки (кодирования) фотоотсчетов, имеющие целью прежде всего сжатие потока регистрируемых отсчетов (минимум на два порядка, т.е. в ~ 100 раз).

Известные данные о строении системы РП можно кратко резюмировать следующим образом. Поля каждого из типов ганглиозных клеток (всего типов ~ 20) организованы в относительно регулярную мозаику, равномерно покрывающую поверхность сетчатки, соседние поля дополняют друг друга как кусочки пазла [14]. При этом у некоторых пар ганглиозных клеток, называемых ON- и OFF-клетками, участки РП на сетчатке могут совпадать, но логически они реагируют на их засветку/затемнение по-разному [15]. А именно, ON-клетки активируются при стимуляции рецепторов в центре РП и тормозятся при стимуляции рецепторов в концентрическом окружении, тогда как OFF-клетки, наоборот, активируются при стимуляции рецепторов в окружении и ингибируются при стимуляции рецепторов в центре РП.

В свете изложенной концепции рецептивных полей ограничимся в выборе процедур кодирования классом методов оптимального параметриче-

ского оценивания параметров семейства плотностей распределений $\mathcal{G} = \{\rho(\vec{x}; \vec{\theta})\}, \vec{x} \in \Omega, \vec{\theta} \in \Theta \subset \mathbb{R}^{2K}$, в качестве которого выберем семейство смесей с заданными компонентами распределений [9]:

$$\rho(\vec{x}; \vec{\theta}) = \sum_{i=1}^K w_i \rho_{ic}(\vec{x}) + v_i \rho_{is}(\vec{x}), \quad (4)$$

$$\sum_{i=1}^K w_i + v_i = 1,$$

где K – количество пар, перекрывающихся ON- и OFF-ганглиозных клеток заданного типа, $\rho_{ic}(\vec{x})$ – плотность распределения вероятности отсчета для центра i -й пары, $\rho_{is}(\vec{x})$ – для её антагонистического концентрического окружения, w_i и v_i – соответствующие им веса в смеси. Таким образом, множество параметров модели есть все ее веса $\vec{\theta} = \{w_i, v_i\}$, и вычисление их оценок по выборочному представлению $X_k = \{\vec{x}_i\}$ рассматривается как кодирование изображения. В данном контексте наилучшее в плане восприятия перцептивное кодирование синтезируется на основе метода максимального правдоподобия Р. Фишера [10]:

$$\vec{\theta}^{ML} = \arg \max_{\vec{\theta} \in \Theta} \ln \rho(X_k; \vec{\theta}), \quad (5)$$

$$\rho(X_k; \vec{\theta}) = \prod_{j=1}^k \rho(\vec{x}_j; \vec{\theta}),$$

где совместное распределение $\rho(X_k; \vec{\theta})$ отсчетов представления задано в соответствии со свойствами статистического описания X_k (3). Отметим в этой связи, что модель смеси (4) будет при этом оценкой изображения $I(\vec{x})$.

Параметры максимального правдоподобия $\vec{\theta}^{ML} = \{w_i^{ML}, v_i^{ML}\}$, соответствующие функции правдоподобия $\rho(X_k; \vec{\theta})$ (5), могут быть найдены методом неопределенных множителей Лагранжа с учетом единственного ограничения $\sum_{i=1}^K w_i + v_i = 1$ (4). В результате получается следующая система уравнений:

$$\frac{1}{k} \sum_{j=1}^k \frac{\rho_{lc}(\vec{x}_j)}{\sum_{i=1}^K w_i^{ML} \rho_{ic}(\vec{x}_j) + v_i^{ML} \rho_{is}(\vec{x}_j)} = 1, \quad (6)$$

$$\frac{1}{k} \sum_{j=1}^k \frac{\rho_{ls}(\vec{x}_j)}{\sum_{i=1}^K w_i^{ML} \rho_{ic}(\vec{x}_j) + v_i^{ML} \rho_{is}(\vec{x}_j)} = 1.$$

В общем случае (нелинейная) система (6) не имеет интерпретируемых аналитических решений. Однако ее можно привести к удобной для рекуррентных вычислений форме, используемой в методах поиска неподвижных точек уравнений вида $\vec{\theta} = F(\vec{\theta})$, если домножить уравнения (6) на w_i^{ML} и v_i^{ML} и переписать полученную систему в итерационном виде (n – номер итерации):

$$\begin{aligned}
 w_l^{(n+1)} &= \frac{1}{k} \sum_{j=1}^k \frac{w_l^{(n)} \rho_{lc}(\vec{x}_j)}{\sum_{i=1}^K w_i^{(n)} \rho_{lc}(\vec{x}_j) + v_i^{(n)} \rho_{ls}(\vec{x}_j)}, \\
 v_l^{(n+1)} &= \frac{1}{k} \sum_{j=1}^k \frac{v_l^{(n)} \rho_{ls}(\vec{x}_j)}{\sum_{i=1}^K w_i^{(n)} \rho_{lc}(\vec{x}_j) + v_i^{(n)} \rho_{ls}(\vec{x}_j)}.
 \end{aligned}
 \tag{7}$$

Заметим, что если интерпретировать слагаемые в суммах (7) как оценки апостериорных вероятностей того, что $\vec{x}_j$ принадлежит центру или окружению i -го рецептивного поля, то система (7) будет представлять собой второй шаг М шаг хорошо известного 2-шагового (на каждой итерации) ЕМ-алгоритма (Е шаг заключается в вычислении самих слагаемых). Поскольку существует обширная литература, посвященная различным аспектам ЕМ-алгоритма, включая вопросы его численной реализации, система уравнений (7) открывает широкие возможности в области синтеза методов перцептивного кодирования изображений.

Выводы

Основываясь на специфике выборочных представлений, удалось сформировать генеративный (порождающий) подход к вопросам синтеза методов перцептивного кодирования изображений, который автоматически вводит рассматриваемую проблему в круг задач машинного обучения и, в частности, в область итеративных алгоритмов, подобных ЕМ-алгоритму.

В целом, основываясь на полученных в работе результатах и проведенных численных экспериментах, можно выразить надежду, что предложенный в работе подход найдет как дальнейшее свое теоретическое развитие, так и эффективное использование в прикладных задачах.

Список литературы

1. Fossum E. The Invention of CMOS Image Sensors: A Camera in Every Pocket // 2020 Pan Pacific Microel. Symp. 2020. P. 1–6.
2. Gigajot Announces the World's Highest Resolution Photon Counting Sensor // Press release: <https://www.prnewswire.com/news-releases/gigajot-announces-the-worlds-highest-resolution-photon-counting-sensor-301516410.html>, accessed 2022/07/01.
3. Sejnowski T.J. The unreasonable effectiveness of deep learning in artificial intelligence // Proc. of the National Academy of Sciences. 2020. V. 117(48). P. 30033.
4. Bishop C.M., Lasserre J. Generative or Discriminative? Getting the Best of Both Worlds // Bernardo J.M. [et al.]. (eds.) Bayesian Statistics 8. 2007.
5. Stroustrup B. What is object-oriented programming? // IEEE software. 1988. V. 5, N 3. P. 10–20.

6. Kershner V., Antsiperov V. Image Coding by Samples of Counts as an Imitation of the Light Detection by the Retina // Proc. of the 11th International Conference on Pat-tern Recognition Applications and Methods – ICPRAM. 2022. P. 41-50.
7. Antsiperov V.E. Representation of Images by the Optimal Lattice Partitions of Random Counts // Pattern Recognition and Image Analysis. 2021. V. 31(3). P. 381–393.
8. Scott D.W. Multivariate density estimation: theory, practice, and visualization. 2nd edition. New Jersey : Wiley, Hoboken, 2015.
9. McLachlan G.J., Lee S.X., Rathnayake S.I. Finite Mixture Models. // Annual Review of Statistics and Its Application. 2019. V. 6, N 1. P. 355-378.
10. Aldrich J.R.A. Fisher and the Making of Maximum Likelihood 1912-1922 // Statistical Science. 1997. V. 12, N 3. P. 162-176.
11. Fox M. Quantum Optics: An Introduction. Oxford Univ. Press. 2006.
12. Jayant N., Johnston J., Safranek R. Perceptual coding of images // Proc of SPIE. 1913. N 1. P. 168–178.
13. Schiller P.H., Tehovnik E. Vision and the Visual System. Oxford Univ. Press. 2015.
14. Gauthier J.L., Field G.D., et. al. Receptive Fields in Primate Retina Are Coordinated to Sample Visual Space More Uniformly // PLoS Biology. 2009. V. 7, N 4.
15. Kuffler S.W. Discharge patterns and functional organization of mammalian retina // J. of Neurophysiology. 1953. V. 16, N 1. P. 37–68.

А.Ю. ДОРГОВСанкт-Петербургский государственный электротехнический университет «ЛЭТИ»
vaksa2006@yandex.ru

ПРИМЕНЕНИЕ БЫСТРЫХ НЕЙРОННЫХ СЕТЕЙ ДЛЯ КОРРЕЛЯЦИОННЫХ ИЗМЕРЕНИЙ

В работе представлены методы построения топологии и параметрического обучения быстрых нейронных сетей (БНС) для задач корреляционных измерений одномерных сигналов и изображений. Описана математическая модель БНС. Отмечена связь быстрых алгоритмов с самоподобными структурами. Показан способ мультипликативного представления произвольных дискретных функций и изображений. Предложены алгоритмы построения топологии БНС и обучения для реализации корреляционного дискриминатора.

Ключевые слова: *линейный дискриминант, быстрая нейронная сеть, фрактальные произведения, самоподобные структуры, изображение.*

Введение

Один из основных способов распознавания сигналов состоит в сопоставлении сигнала с эталоном. Простейшей мерой сходства является линейный дискриминант Фишера [1]. В частном случае этот дискриминант представляет собой меру взаимной энергии сигналов и выражается через нормированное скалярное произведение:

$$d = (x, e) / \sqrt{(x, x)(e, e)} > \alpha,$$

где x – неизвестный сигнал, представленный вектором, e – вектор эталонного сигнала, скобки $(,)$ – обозначают скалярное произведение векторов, скаляр α определяет пороговый уровень различения сигналов.

Разработку алгоритма быстрого преобразования Фурье (БПФ) условно можно считать одним из выдающихся достижений второй половины XX века. Дальнейшим развитием этого направления является класс перестраиваемых быстрых алгоритмов. Сохраняя структуру графа и изменяя только параметры базовых операций в перестраиваемых быстрых алгоритмах, можно переходить от одного быстрого преобразования к другому. Первые предложения по построению обобщённого ортогонального преобразования были высказаны Эндрюсом и Каспари [2] в 70-х годах прошлого века. А первые подходы к обучению подобных преобразований

были развиты в работах А. И. Солодовникова и его научной группы [3]. В то время подобный класс преобразований называли *приспособленными быстрыми преобразованиями*.

Возможность перестройки значений весовых коэффициентов и многослойная структура алгоритма роднит быстрые ортогональные перестраиваемые преобразования с многослойными нейронными сетями прямого распространения. Иногда используют термин – *ортогональные нейронные сети*. В рамках данной парадигмы быстрые перестраиваемые преобразования являются частным случаем многослойных нейронных сетей и отличаются от последних линейными функциями активации и нулевыми смещениями в нейронах. Для обозначения нового класса сетей используется термин *быстрые нейронные сети* (БНС) [4].

Благодаря своей структуре БНС обладают специфичными алгоритмами обучения, принципиально отличающимся от классического Error Back Propagation отсутствием обратных связей по ошибке обучения. Это качество обеспечивает высокую скорость и абсолютную сходимость обучающего алгоритма. В основе алгоритмов обучения БНС лежит доказанное свойство структурной фрактальности сети, которое можно выразить системным инвариантом морфологического уровня [5]. Идея метода обучения БНС к одной или нескольким функциям основана на представлении каждой функции заданного набора в виде предфрактального произведения, отвечающего мультипликативной форме представления элементов матрицы быстрого преобразования.

В данной работе показано использование БНС для построения дискриминаторов одномерных сигналов и изображений. Дано описание математической модели БНС, представлены методы построения топологии и обучения БНС для задачи корреляционных измерений.

Математическая модель одномерной БНС

В работе Гуда [6] впервые было показано, что элементы матрицы быстрого преобразования Фурье можно представить в виде произведения элементов матриц базовых операций. На рис. 1 представлен граф быстрого преобразования в топологии Гуда с явным выделением базовых операций. В терминах нейронной сети базовая операция графа типа «бабочка» – это однослойная нейронная сеть с размерностью рецепторного и аксонового полей, равной 2.

Базовую операцию определим матрицей $W_{i_m}^m$, где m – номер слоя и i_m – номер базовой операции в пределах слоя. Элементы матриц базовых

операций обозначим через $w_{i_m}^m(u_m, v_m)$, где u_m, v_m определяют номер строки и номер столбца матрицы. В общем случае размерности полей базовой операции могут быть отличны от 2. В алгоритмах быстрых преобразований удобно использовать нумерацию индексов, начиная с нулевого значения. Гуд показал, что элементы матрицы быстрого преобразования Фурье размерности $N = 2^n$ могут быть представлены в виде

$$h(U, V) = w_{i_0}^0(u_0, v_0) w_{i_1}^1(u_1, v_1) \dots w_{i_{n-2}}^{n-2}(u_{n-2}, v_{n-2}) w_{i_{n-1}}^{n-1}(u_{n-1}, v_{n-1}), \quad (1)$$

где топология преобразования определяется кортежами:

$$\begin{aligned} U^m &= \langle v_{m-1} v_{m-2} \dots v_0 u_{n-1} u_{n-2} \dots u_m \rangle, \\ V^m &= \langle v_m v_{m-1} \dots v_0 u_{n-1} u_{n-2} \dots u_{m+1} \rangle, \\ i^m &= \langle v_{m-1} \dots v_0 u_{n-1} u_{n-2} \dots u_{m+1} \rangle. \end{aligned} \quad (2)$$

Здесь кортежи используются для поразрядного представления чисел в позиционной системе счисления. Например, для системы счисления с основанием 2 имеем

$$u = \langle u_{n-1} u_{n-2} \dots u_0 u_1 \rangle = u_{n-1} 2^{n-1} + u_{n-2} 2^{n-2} + \dots + u_1 2 + u_0.$$




Рис. 1. Топологическая схема Гуда для размерности быстрого преобразования 8 с явным выделением базовых операций

В кортеже поразрядного представления крайний левый разряд считается старшим. Значение U^m определяет номер рецептора, а значение V^m – номер нейрона в слое m . Нумерация слоёв сети начинается с нуля, полное число слоёв равно n . Обобщённая теорема мультипликативной факторизации элементов матриц быстрых преобразований представлена в работе [7].

Мультипликативное представление дискретных функций

Рассмотрим сигнал, заданный функцией $f(u)$ на дискретном интервале длиной $N = p_0 p_1 \dots p_{n-1}$, где p_m – произвольные целые числа. Представим аргумент функции в позиционной многоосновной системе счисления с основаниями $p_0, p_1, \dots, p_{n-1}$. Формула перехода, как известно, имеет вид

$$u = \langle u_{n-1} u_{n-2} \dots u_0 \rangle = u_{n-1} p_{n-2} p_{n-3} \dots p_0 + \dots \\ \dots + u_{n-2} p_{n-3} p_{n-4} \dots p_0 + \dots + u_1 p_0 + u_0,$$

где $u_i \in [0, p_i - 1]$ – разрядные переменные. В результате данного преобразования сигнал представляется как многомерная функция $f\langle u_{n-1} u_{n-2} \dots u_0 \rangle$. Каждый аргумент функции определяет некоторый масштабный срез сигнала. Зафиксируем все аргументы функции, кроме u_m . Варьируя свободный аргумент u_m , получим выборку S_m (с числом элементов p_m). Фрактальным фильтром [7] частотной локализации m называется произвольный функционал $F(S_m)$, определённый на выборке S_m . Операцию фрактальной фильтрации можно записать в виде

$$f_{out} \langle u_{n-1} u_{n-2} \dots u_{m+1} u_{m-1} \dots u_0 \rangle = \underset{u_m}{F} (f_{inp} \langle u_{n-1} u_{n-2} \dots u_0 \rangle).$$

В простейшем варианте фрактальный фильтр выполняет суммирование значений функции по аргументу u_m . Если $m = 0$, то такой фильтр генерализует сигнал, сглаживая мелкие детали. Фрактальная фильтрация по аргументу u_m приводит к сокращению интервала определения сигнала в p_m раз.

Рассмотрим цепочку фрактальных фильтров, показанную на рис. 2.




Рис. 2. Цепочка фрактальных фильтров

Выходные сигналы для фильтров цепочки определяются рекуррентным соотношением:

$$f_m \langle u_{n-1} \dots u_m \rangle = F_{u_{m-1}}(f_{m-1} \langle u_{n-1} \dots u_m u_{m-1} \rangle).$$

Введём функции:

$$\varphi_{i^m}(u_m) = \frac{f_m \langle u_{n-1} u_{n-2} \dots u_m \rangle}{f_{m+1} \langle u_{n-1} u_{n-2} \dots u_{m+1} \rangle}, \quad m = 0, 1, \dots, n-2,$$

где $i^m = \langle u_{n-1} u_{n-2} \dots u_{m+1} \rangle$. Используя определения функций, можно записать:

$$f_m \langle u_{n-1} u_{n-2} \dots u_m \rangle = \varphi_{i^m}(u_m) f_{m+1} \langle u_{n-1} u_{n-2} \dots u_{m+1} \rangle, \quad m = 0, 1, \dots, n-2. \quad (3)$$

Из рекуррентных соотношений (3) непосредственно следует

$$f(u) = f_0 \langle u_{n-1} u_{n-2} \dots u_0 \rangle = \phi_{i^0}(u_0) \phi_{i^1}(u_1) \dots \phi_{i^{n-2}}(u_{n-2}) \phi_{i^{n-1}}(u_{n-1}). \quad (4)$$

Топология и обучение одномерной корреляционной нейронной сети

Будем полагать, что входной и эталонные сигналы нормированы к энергии, так что $(x, x) = 1$ и $(e, e) = 1$. В этом случае дискриминант определяется скалярным произведением

$$d = (x, e).$$

Скалярное произведение можно рассматривать как произведение вектора-строки x на одностолбцовую матрицу $H = e'$. Или в покомпонентном выражении:

$$d = \sum_U x(U) h(U, V).$$

Будем полагать, что матрица H является матрицей быстрого преобразования с топологией Гуда. Поскольку сеть имеет только один выход, то

$$V = V^{n-1} = \langle 0_{n-1} 0_{n-2} \dots 0_1 0_0 \rangle.$$

Таким образом, все разрядные переменные $v_m = 0$ для $m = 0, 1, \dots, n-1$. То есть каждая базовая операция также будет иметь только один выход с локальным номером 0. Выражения (2) для топологии сети в этом случае примут вид

$$\begin{aligned}
 U^m &= \langle 0_{m-1} 0_{m-2} \dots 0_0 u_{n-1} u_{n-2} \dots u_m \rangle, \\
 V^m &= \langle 0_m 0_{m-1} \dots 0_0 u_{n-1} u_{n-2} \dots u_{m+1} \rangle, \\
 i^m &= \langle 0_{m-1} \dots 0_0 u_{n-1} u_{n-2} \dots u_{m+1} \rangle.
 \end{aligned} \tag{5}$$

В частности, для входного слоя сети $m=0$, в этом случае имеем $i^0 = \langle u_{n-1} u_{n-2} \dots u_1 \rangle$. Полагая, что разрядные переменные принимают значения $u_i \in [0, 1, \dots, p_i - 1]$, можно сделать вывод, что слой будет содержать $Z^0 = p_{n-1} p_{n-2} \dots p_1$ базовых операций. Следующий слой, $m=1$, будет содержать $Z^1 = p_{n-1} p_{n-2} \dots p_2$ базовых операций и т.д., для последнего слоя имеем $i^{n-1} = \langle 0_{n-1} 0_{n-2} \dots 0_0 \rangle = 0$, и поэтому этот слой будет содержать только одну базовую операцию. Топология межслойных переходов определяется правилом $V^{m-1} = U^m$.

На рис. 3 представлен топологический граф коррелирующей сети для размерности $N = 2^3$. Каждая базовая операция данной нейронной сети представляет собой один нейрон, имеющий два входа. Граф сети строится непосредственно по топологическим выражениям. Детали построения топологического графа изложены в работе [7].




Рис. 3. Топология коррелирующей сети

Сравним между собой выражения (1) и (4). Нетрудно заметить, что при топологии (5) они совпадают. Отсюда сразу следует правило обучения нейронной сети:

$$w_{i^m}^m(u_m, 0) = \phi_{i^m}(u_m).$$

Математическая модель двумерных БНС

Обозначим через $F(U_y, U_x)$ матрицу изображения размерностью $N_y \times N_x$. При воздействии на изображение линейного преобразования $h(U_y, U_x; V_y, V_x)$ получается массив из $M_y \times M_x$ коэффициентов. Двумерное преобразование выполняется по правилу

$$S(V_y, V_x) = \sum_{U_y=0}^{N_y-1} \sum_{U_x=0}^{N_x-1} F(U_y, U_x) h(U_y, U_x; V_y, V_x).$$

Необходимым условием существования быстрого алгоритма является возможность мультипликативной декомпозиции значений обеих размерностей изображения в равное число сомножителей:

$$N_y = p_0^y p_1^y \dots p_{n-1}^y, \quad N_x = p_0^x p_1^x \dots p_{n-1}^x.$$

Индексы x, y здесь означают принадлежность к осям координат исходного изображения. Данное условие не является жёстким ограничением, поскольку некоторые сомножители могут быть единичными. Тем не менее чем больше число неединичных сомножителей в декомпозициях, тем выше вычислительная эффективность быстрого алгоритма. Используя сомножители декомпозиций, координаты точек изображения представим в позиционной системе счисления со смешанными основаниями:

$$U_y = \langle u_{n-1}^y u_{n-2}^y \dots u_1^y u_0^y \rangle, \quad U_x = \langle u_{n-1}^x u_{n-2}^x \dots u_1^x u_0^x \rangle, \quad (6)$$

где вес m -го разряда определяется выражением $p_{m-1}^* p_{m-2}^* \dots p_1^* p_0^*$, а u_m^* — является разрядной переменной, принимающей значения $[0, p_m^* - 1]$ (звёздочка здесь и далее заменяет индексы x, y). Аналогично можно представить координаты коэффициентов в выходной плоскости $[V_y, V_x]$:

$$V_y = \langle v_{n-1}^y v_{n-2}^y \dots v_1^y v_0^y \rangle, \quad V_x = \langle v_{n-1}^x v_{n-2}^x \dots v_1^x v_0^x \rangle.$$

Для математического описания топологического графа быстрого алгоритма удобно использовать поразрядную форму представления чисел.

Например, для топологии Гуда граф может быть описан набором кортежей:

$$\begin{aligned} U_*^m &= \langle v_{m-1}^* v_{m-2}^* \dots v_0^* u_{n-1}^* u_{n-2}^* \dots u_m^* \rangle, \\ V_*^m &= \langle v_m^* v_{m-1}^* \dots v_0^* u_{n-1}^* u_{n-2}^* \dots u_{m+1}^* \rangle, \\ i_*^m &= \langle v_{m-1}^* v_{m-2}^* \dots v_0^* u_{n-1}^* u_{n-2}^* \dots u_{m+1}^* \rangle, \end{aligned} \quad (7)$$

где позиционное представление координат U_y^m, U_x^m и V_y^m, V_x^m определяет топологию во внутренних слоях быстрого алгоритма. На основе данных кортежей может быть построен топологический граф алгоритма [7]. На рис. 4 приведён пример построения подобного графа для размерностей $N_y \times N_x = 8 \times 8$, $M_y \times M_x = 8 \times 8$.




Рис. 4. Топологический граф быстрого алгоритма двумерного преобразования

В общем случае топологии направлений x и y могут различаться. На топологическом графе показаны базовые операции $w_{i_x^m, i_y^m}^m(u_m^y u_m^x; v_m^y v_m^x)$ представляющие собой четырёхмерные матрицы размерности $[p_m^y, p_m^x; p_m^y, p_m^x]$. Так же как и в одномерном случае, каждый элемент четырёхмерной матрицы преобразования H выражается через элементы базовых операций в виде произведения:

$$\begin{aligned} h(U_y, U_x; V_y, V_x) &= w_{i_x^{n-1}, i_y^{n-1}}^{n-1}(u_{n-1}^y u_{n-1}^x; v_{n-1}^y v_{n-1}^x) w_{i_x^{n-2}, i_y^{n-2}}^{n-2}(u_{n-2}^y u_{n-2}^x; v_{n-2}^y v_{n-2}^x) \dots \\ &\dots w_{i_x^0, i_y^0}^0(u_0^y u_0^x; v_0^y v_0^x), \end{aligned} \quad (8)$$

где поразрядные выражения индексов ядер слоя m для выбранной топологии имеют вид: $i_*^m = \langle v_{m-1}^* v_{m-2}^* \dots v_0^* u_{n-1}^* u_{n-2}^* \dots u_{m+1}^* \rangle$.

Мультипликативное представление дискретных изображений

Алгоритм мультипликативного представления основан на идеях последовательной фрактальной фильтрации и для двумерного случая представляет собой кратно-масштабную обработку изображений, последовательно сжимающую его размеры вплоть до единственной точки [7]. Схему фрактальной фильтрации можно представить в виде пирамиды, показанной на рис. 5. Основанием пирамиды является исходное изображение, $F(U_y, U_x)$, для которого аргументы U_y и U_x представлены в позиционной системе счисления (см. (6)). В этом представлении координат зафиксируем все разряды, кроме двух младших u_0^y и u_0^x . Если варьировать эти разряды по всем возможным значениям, то получим выборку размером $p_0^y \times p_0^x$.




Рис. 5. Алгоритм мультипликативной декомпозиции изображений

Под фрактальным фильтром будем понимать произвольный функционал Φ , заданный на этой выборке. Формально фильтр можно записать в виде выражения:

$$F_1(\langle u_{n-1}^y u_{n-2}^y \dots u_1^y \rangle, \langle u_{n-1}^x u_{n-2}^x \dots u_1^x \rangle) = \Phi_{(u_0^y, u_0^x)} \left[F(\langle u_{n-1}^y u_{n-2}^y \dots u_1^y u_0^y \rangle, \langle u_{n-1}^x u_{n-2}^x \dots u_1^x u_0^x \rangle) \right].$$

Очевидно, что изображение F_1 будет уменьшенным по размерам в $p_0^y \times p_0^x$ раз по отношению к исходному изображению. Функционалом, например, может быть правило вычисления среднего значения выборки

или её медианы. Исходное изображение теперь можно формально представить в виде произведения:

$$F\left(\langle u_{n-1}^y u_{n-2}^y \cdots u_1^y u_0^y \rangle, \langle u_{n-1}^x u_{n-2}^x \cdots u_1^x u_0^x \rangle\right) = \\ = F_1\left(\langle u_{n-1}^y u_{n-2}^y \cdots u_1^y \rangle, \langle u_{n-1}^x u_{n-2}^x \cdots u_1^x \rangle\right) f_{j_0^y j_0^x}(u_0^y, u_0^x),$$

где $f_{j_0^y j_0^x}(u_0^y, u_0^x)$ – набор двумерных функций-множителей, зависящих от разрядных переменных u_0^y и u_0^x , а индексы j_0^y, j_0^x выделяют функцию из набора. Для получения функций множителей достаточно выполнить скалярное деление изображения F на изображение F_1 при варьировании всех разрядных переменных. Изображение F_1 в свою очередь также может быть представлено как произведение изображения F_2 на множители из набора $f_{j_1^y j_1^x}(u_1^y, u_1^x)$. Повторяя операцию фрактальной фильтрации и разложения многократно, достигнем вершины пирамиды изображений и получим в результате мультипликативную декомпозицию исходного изображения:

$$F\left(\langle u_{n-1}^y u_{n-2}^y \cdots u_1^y u_0^y \rangle, \langle u_{n-1}^x u_{n-2}^x \cdots u_1^x u_0^x \rangle\right) = f_{j_{n-1}^y j_{n-1}^x}(u_{n-1}^y, u_{n-1}^x) \cdot \\ \cdot f_{j_{n-2}^y j_{n-2}^x}(u_{n-2}^y, u_{n-2}^x) \cdots f_{j_1^y j_1^x}(u_1^y, u_1^x) f_{j_0^y j_0^x}(u_0^y, u_0^x), \quad (9)$$

где $j_m^y = \langle u_{n-1}^y u_{n-2}^y \cdots u_{m+1}^y \rangle$ и $j_m^x = \langle u_{n-1}^x u_{n-2}^x \cdots u_{m+1}^x \rangle$.

Топология и обучение двумерной корреляционной нейронной сети

Как и в одномерном случае будем полагать, что входное и эталонное изображения нормированы к энергии, так что $(x, x) = 1$ и $(e, e) = 1$. В этом случае дискриминант определяется скалярным произведением $d = (x, e)$. Скалярное произведение можно рассматривать как произведение изображения x на матрицу $H = e'$, состоящую из одной плоскости. Или в покоординатном выражении:

$$d = \sum_{U_x, U_y} x(U_x, U_y) h(U_x, U_y; V_x, V_y).$$

Будем полагать, что матрица H является матрицей быстрого преобразования с топологией Гуда. Поскольку сеть имеет только один выход, то

$$V_y = \langle 0_{n-1}^y 0_{n-2}^y \cdots 0_1^y 0_0^y \rangle, \quad V_x = \langle 0_{n-1}^x 0_{n-2}^x \cdots 0_1^x 0_0^x \rangle.$$

Таким образом, все разрядные переменные $v_m^* = 0$ для $m = 0, 1, \dots, n-1$. То есть каждая базовая операция также будет иметь только один выход с локальным номером (0,0). Выражения (7) для топологии сети в этом случае примут вид

$$\begin{aligned} U_*^m &= \langle 0_{m-1}^* 0_{m-2}^* \dots 0_0^* u_{n-1}^* u_{n-2}^* \dots u_m^* \rangle, \\ V_*^m &= \langle 0_m^* 0_{m-1}^* \dots 0_0^* u_{n-1}^* u_{n-2}^* \dots u_{m+1}^* \rangle, \\ i_*^m &= \langle 0_{m-1}^* 0_{m-2}^* \dots 0_0^* u_{n-1}^* u_{n-2}^* \dots u_{m+1}^* \rangle. \end{aligned} \quad (10)$$

На рис. 6 представлен топологический граф коррелирующей сети для изображения $N \times N = 2^3 \times 2^3$. Каждая базовая операция данной нейронной сети представляет собой один нейрон, имеющий четыре пространственных входа.




Рис. 6. Топология коррелирующей сети

Сравним между собой выражения (8) и (9). Нетрудно заметить, что при топологии (10) они совпадают. Отсюда сразу следует правило обучения нейронной сети:

$$w_{i_y^m, i_y^m}^m(u_m^y u_m^x; 0_m^y 0_m^x) = f_{i_y^m, i_y^m}^m(u_m^y, u_m^x).$$

Заключение

Быстрые нейронные сети относятся к широкому классу самоподобных многослойных нейронных сетей [8]. Самоподобные сети с регулярной структурой обладают уникальным свойством аналитического представле-

ния графа топологической модели, что позволяет разработать быстрые абсолютно сходящиеся алгоритмы обучения с конечным числом вычислительных операций. В данной статье алгоритм быстрого преобразования с топологией Гуда использован как пример, подобный алгоритм может быть реализован для топологии Кули – Тьюки или любой иной топологии быстрых преобразований.

Представленные в работе результаты показывают, что сети могут быть эффективно использованы для корреляционных измерений изображений. Подобным образом могут быть построены дискриминаторы для локализации изображений и объектов в одномерных и многомерных пространствах. Более того, регулярный лес корреляционных сетей позволяет реализовать быстрые нейронные сети глубокого обучения [9], способные дообучаться новым эталонам без потери накопленных знаний.

Список литературы

1. Фишер Р.А. Статистические методы для исследователей. Москва : Госстатиздат. 1958. 267 с.
2. Andrews H.C., Caspari K.L. A General Techniques for Spectral Analysis // IEEE. Tr. Computer. 1970. V. C-19, N 1. P. 16–25.
3. Солодовников А.И., Спиваковский А.М. Основы теории и методы спектральной обработки информации. Ленинград : Изд-во ЛГУ. 1986. 272 с.
4. Дорогов А.Ю. Быстрые нейронные сети: Проектирование, настройка, приложения // Лекции по нейроинформатике Ч. 1. Научная сессия МИФИ–2004. VI Всероссийская научно-техническая конференция «Нейроинформатика–2004». Москва : МИФИ, 2004. С. 69-135.
5. Дорогов А. Ю., Шестопалов М. Ю. Нейросетевое моделирование регулярных фракталов // Нейрокомпьютеры разработка и применение. 2007. № 6. С. 3–15.
6. Good I.J. The Interaction Algorithm and Practical Fourier Analysis // Journal of Royal Statistical Soseity. Ser.B. 1958. V. 20, N 2. P. 361-372.
7. Дорогов А.Ю. Теория и проектирование быстрых перестраиваемых преобразований и слабосвязанных нейронных сетей. Санкт-Петербург : «Политехника». 2014. 328 с.
8. Дорогов А.Ю. Самоподобные структуры многослойных нейронных сетей // XXII Международная научно-техническая конференция «Нейроинформатика-2020». Сборник научных трудов. Москва : НИЯУ МИФИ. 2020. С. 214–224.
9. Дорогов А.Ю. Быстрые нейронные сети глубокого обучения // Сборник докладов III Международной научной конференции по проблемам управления в технических системах (CTS'2019). Санкт-Петербург : СПбГЭТУ «ЛЭТИ». 2019. С. 275-280.

**Я.М. КАРАНДАШЕВ, Е.В. МИХАЛЬЧЕНКО,
М.Ю. МАЛЬСАГОВ, В.Ф. НИКИТИН**

Федеральный научный центр Научно-исследовательский институт системных исследований Российской академии наук, Москва
karandashev@niisi.ras.ru, mikhmalchenkolena@yandex.ru,
malsagov@niisi.ras.ru, vfnikitin77@rambler.ru

АППРОКСИМАЦИЯ ХИМИЧЕСКОЙ КИНЕТИКИ ИСКУССТВЕННОЙ НЕЙРОННОЙ СЕТЬЮ*

Добавление давления системы как новой переменной значительно усложняет задачу аппроксимации изменения концентраций веществ в смеси в процессе химических реакций. Величина начального давления оказывает влияние как на величину данных, так и на скорость протекающих реакций. В настоящей работе нам удалось построить одну нейронную сеть, способную описывать модель при различных давлениях, не жертвуя при этом ни точностью решения, ни скоростью работы.

Ключевые слова: численное моделирование химических процессов, горение, детонация, нейронные сети, глубокое обучение.

Введение

Во многих случаях задача расчета газодинамических процессов, проходящих в двигателях, в энергетических установках, в производственных и иных условиях, включает физико-химические взаимодействия. Расчет этих взаимодействий без сильных дополнительных упрощений, снижающих предсказательные способности математического моделирования, представляет собой сложную математическую задачу, традиционно решаемую методами, которые при всей возможной их оптимизации занимают большую, если не подавляющую часть расчетного времени. Если рассматривается нестационарный процесс, включающий такие физические явления, как детонация, переход к детонации, зажигание горючей смеси, распространение волн горения или детонации по системе, то получение расчетных данных даже за весьма малое физическое время требует долгой работы суперкомпьютерных систем. Попытка же ускорить время расчета

* Настоящая работа выполнена в рамках государственного задания по проведению фундаментальных научных исследований по теме "Исследование нейроморфных систем обработки больших данных и технологии их изготовления" № FNEF-2022-0003.

обычными для этого простыми методами, такими как огрубление расчетной сетки или экстраполяция результатов, полученных на начальном этапе расчета, на значительно больший временной период, не гарантирует отсутствия грубых отклонений численной модели от исходной математической. Тем самым узким местом математического моделирования сложных газодинамических процессов становится расчет химических взаимодействий.

В последнее время с развитием графических ускорителей и методов глубокого обучения участились попытки аппроксимации химической кинетики искусственными нейронными сетями. Преимущества такого подхода очевидны: для нейронной сети не критично количество задействованных в процессе веществ (чем больше, тем лучше); подавляющее количество вычислений – это скалярное умножение матрицы на вектор, что можно эффективно распараллелить, то есть получить значительное ускорение. При этом одна и та же архитектура сети может использоваться для различных кинетических механизмов, достаточно изменить входной вектор и выходной, обучить сеть на новых данных.

Преимущества нейросетевого подхода продемонстрировали в недавних работах [1–3]. Например, в [1–2] предлагают обучать по одной маленькой сети для каждого вещества, задействованного в процессе. Затем параллельно объединить эти сети в одну с общим входом и выходом. Хотя авторы не упоминают, с какими численными методами они сравнивают сеть, однако указывают 35-кратное ускорение. В работе [3] несколько одинаковых небольших сетей с остаточными связями (ResNet) соединяются последовательно, по количеству временных шагов, на которые делается аппроксимация. Такой подход позволяет достичь хорошей точности при прогнозировании на десятки, сотни шагов от стартового состояния.

Тем не менее решения эти были не полны. Хотя в работах [1–3] и многих других давление в системе учитывалось явно, обучающие данные создавались для одной величины давления или небольшого диапазона. То есть, чтобы учесть большой интервал начальных условий, требуется обучать отдельную нейронную сеть для каждого небольшого диапазона или значения давления.

В данной работе нам удалось решить проблему с учетом давления, используя лишь одну небольшую нейронную сеть.

Постановка задачи

В настоящей работе рассматривается задача горения водородно-кислородной смеси в воздушной среде. Начальное состояние системы

задается давлением, температурой и молярными плотностями водорода (H_2), кислорода (O_2), а также элементами воздуха, азотом (N_2) и аргоном (Ar). В процессе горения образуются различные водородно-кислородные соединения (H_2 , O_2 , H_2O , OH , HO_2 , H_2O_2 , H , O), меняется температура среды. Такой процесс преобразования веществ описывается 28 уравнениями химических реакций (механизм GriMech 3.0 (1999)) [4]. Стоит отметить, что азот и аргон не образуют химических соединений с другими веществами, а только влияют на скорость протекания реакций. Поэтому их молярная плотность с течением времени никак не меняется в отличие от остальных веществ. Таким образом, система состоит из 10 переменных (давление, температура и кислородно-водородные соединения) и двух постоянных компонент, значения которых не меняются, но эти значения учитывать все же нужно.

В итоге требуется проследить развитие такой системы от начального состояния на некотором временном интервале. Математически весь процесс обычно описывается системой дифференциальных уравнений:

$$\frac{d\chi}{dt} = f(P, T, \chi). \quad (1)$$

В нашей задаче всего 10 веществ, то есть 10 уравнений в системе (1), без учета уравнений на условия сохранения массы и энергии. Однако подобные задачи обычно содержат сотни и тысячи веществ, что делает применение обычных численных методов практически невозможным. Поэтому развитие в последние годы методов глубокого обучения и графических ускорителей сделало привлекательными попытки использовать искусственные нейронные сети в данной области.

Данные

В табл. 1 приведен пример данных, описывающих развитие системы с течением времени. Наблюдения проводились каждую 0.1 мкс. В таблице представлено начальное состояние химической системы в нулевой момент времени, а также динамика развития через равные промежутки времени. Отметим некоторые «неприятные» особенности получаемых данных. Процесс горения проходит очень быстро, имеет скорее взрывной характер, поэтому зависимости температуры и плотности веществ от времени зачастую быстро приходят в равновесное состояние, уменьшая тем самым количество данных для обучения. Сами компоненты меняются в различных диапазонах. Например, при температуре в 1500 К, молярная плотность какого-нибудь нестабильного радикала (H , OH и т.д.) может

оказаться 10^{-11} , а стабильных веществ (H_2 , O_2) составить 1. В то же время в течение всего процесса азот и аргон вообще не меняют своей величины.

Таблица 1

Пример ненормированных данных

$t, \mu\text{sec}$	T, K	H_2	O_2	H_2O	OH	Ar
0	1386.0440	3.3979849	1.7312092	0	0	1.98
0.1	1386.0439	3.3979848	1.7312091	1.46E-09	3.43E-09	1.98
0.2	1386.0437	3.3979846	1.7312090	9.83E-09	1.14E-08	1.98
0.3	1386.0436	3.3979845	1.7312088	2.92E-08	2.20E-08	1.98
...	...	...	...	...	...	...
53.0	3031.6543	0.6887041	0.2641091	2.21170	0.512013	1.98
53.1	3031.6753	0.6887010	0.2641065	2.21171	0.512014	1.98
53.2	3031.6959	0.6886979	0.2641038	2.21171	0.512015	1.98
...	...	...	...	...	...	...
99.9	3032.6782	0.6885503	0.2639780	2.21207	0.512074	1.98

В предыдущих работах [5, 6] давление системы было фиксировано (1.0 Бар), а временной шаг наблюдений составлял 0.1 мкс. Построить одну нейронную сеть для описания процесса при различных значениях давления оказалось проблематично.




Рис. 1. Изменение молярной плотности водорода при различных начальных давлениях системы. (а) – временной шаг фиксирован, (б) – временной шаг выбирается из уравнения (2)

На рис. 1(а) показан пример изменения молярной плотности водорода в течение 100 временных шагов при трех начальных значениях давления. Как видно из рисунка, величина давления влияет как на величину плотно-

сти, так и на скорость протекания реакции. Влияние на величину плотности вызвано особенностями нормировки данных в модели, предоставленной нам. Это влияние легко устранить делением молярных плотностей на величину давления. А вот со скоростью реакции так не получится. Фиксируя значение временного шага, мы рискуем пропустить при определенном давлении весь процесс горения. На рисунке это хорошо видно. При давлении 1 Бар процесс занимает 20 шагов, при меньшем – еще больше. А вот при давлении 10 Бар нам достается всего 3–4 точки. Значит, при конкретном начальном давлении в системе необходимо выбирать свою величину временного шага. Тогда придется обучать отдельную нейронную сеть для каждого давления или хотя бы интервала давлений. Это очень неудобно.

Однако опытным путем нам удалось подобрать соотношение между давлением и временным шагом:

$$p \cdot dt \sim 0.1. \quad (2)$$

На рисунке 1(б) показано, как выравниваются данные из рис. 1а, если их нормировать на начальное давление и выбрать временной шаг согласно выражению (2). Таким образом, если ввести временной шаг не как свободный параметр, а как зависимую от давления системы величину, мы получим соизмеримые данные для различных давлений, на которых уже можно обучать общую нейронную сеть.

Масштабирование данных. Каждая молярная плотность χ на каждом шагу нормировалась на начальное значение давления.

$$\tilde{\chi} = \frac{\chi}{p_0}. \quad (3)$$

Так как каждое вещество, температура и давление меняются в процессе в разных диапазонах и с разной скоростью, то было решено сделать логарифмическую перенормировку данных, чтобы малые изменения вблизи нуля стали более заметны:

$$y = \ln(1 + X / \varepsilon), \quad (4)$$

где $\varepsilon = 10^{-10}$, $X = (p, T, \chi)$ – логарифмирование применялось ко всему вектору (давление, температура и молярные плотности).

Вдобавок к логарифмическому масштабированию (1) было применено стандартное вычитание среднего и деление на стандартное отклонение:

$$z = \frac{y - \bar{y}}{\sigma_y} . \quad (5)$$

Архитектура нейронной сети

На рис. 2 представлена архитектура нейронной сети. Сеть получилась пятислойная. Первый и последний слой переводят, соответственно, входной 12-мерный вектор в 100-мерное пространство и обратно. Средние три слоя имеют по 100 нейронов, полносвязные, с активационной функцией LeakyReLU. Присутствуют также прямые связи, передающие входной вектор без изменений на выход как в остаточных нейронных сетях (ResNet). В результате была построена простая, компактная нейросеть. Единственное стоит отметить, что молярные плотности азота аргона остаются постоянными, поэтому они просто передаются на выход сети.




Рис. 2. Архитектура нейронной сети

Обучение сети производилось сразу на несколько шагов, т.е. выход сети подавался на вход несколько раз, а функция потерь вычислялась по накопленным данным:

$$Loss = \frac{1}{n_{step}} \sum_{i=1}^{n_{step}} MSE(Y_i, Y_i^{pred}), \quad (6)$$

где n_{step} – количество повторений цикла.

Благодаря суммированию ошибок предсказания на несколько шагов вперёд, сеть автоматически учится учитывать рекуррентное накопление ошибки и минимизировать его. В экспериментах мы использовали $n_{steps} = 50$ шагов.

Результаты

Для обучения и тестирования нейронной сети было создано три набора данных. Первый состоит из 10 000 экспериментов для обучения. Обученная нейронная сеть тестировалась на базе из 4000 экспериментов. Еще 2000 экспериментов использовались для контроля процесса обучения. Каждый эксперимент содержит 500 временных шагов. Величина временного шага в каждом случае определялась из соотношения (2) по начальному давлению.

Средняя квадратичная ошибка обученной сети составила

$$MSE = 0.00011 \pm 0.00058.$$

Полученный результат аналогичен тому, что мы получили в прошлых работах для фиксированного давления в системе. То есть нам удалось расширить область применения нейронной сети без потери в точности и скорости работы.

На рис. 3 представлен результат работы нейронной сети для случайной конфигурации, не входившей ни в тестовую, ни в обучающую выборки. На рисунке представлены данные в исходном масштабе, ненормированные. Как видно, сеть хорошо описывает характер процесса для каждого параметра, несмотря на то, что все они меняются в различных диапазонах.

Результат не идеален. Нейронная сеть обладает множеством настраиваемых параметров: количество нейронов в слоях; вид функции активации и ее параметры; количество слоев и т.д. В данной работе настройка и точный анализ параметров сети не производились. Также можно менять способ обучения. Например, мы пробовали обучать сеть итерационно. Сначала сеть обучалась предсказывать на один шаг, затем дообучалась на 5 шагов, 10, 15 и т.д. Такой подход незначительно увеличивал конечную точность, зато сеть становилась стабильнее. При итерационном подходе проявлялась такая конфигурация, при которой ошибка резко возрастала. Итерационный подход может замедлять обучение в несколько раз и в некоторых случаях может не дать заметных результатов вообще.

Отметим, что при сравнении по времени работы с численным методом, который использовался при генерации данных, нейронная сеть показала в среднем двукратное ускорение.




Рис. 3. Пример эксперимента. Маркерами показан результат нейронной сети, сплошная кривая – эталонный результат

Заключение

При компьютерном моделировании процессов горения наиболее вычислительно трудоёмкая часть состоит в моделировании химической кинетики. Предложенная в данной работе нейронная сеть справляется с этой задачей и является быстрой, легко распараллеливаемой альтернативой трудоёмкому численному решению при наличии достаточной обучающей выборки.

В данной работе нам удалось ввести в модель учет давления системы. Наличие давления в модели проводило к тому, что не только данные значительно менялись по величине, но и сильно изменялась скорость происходящих процессов. Эти изменения делали невозможным обучение одной сети для всего диапазона давлений. Внеся незначительные изменения в нормировку данных, а также учитывая зависимость давления от временного шага, мы смогли построить одну нейронную сеть, описывающую

всю модель, не потеряв при этом ни в скорости работы, ни в качестве результата.

Список литературы

1. Peng, W.Y. and Pinkowski, N.H. «Efficient and Accurate Time-Integration of Combustion Chemical Kinetics Using Artificial Neural Networks», 2017.
2. Sharma, A.J., Johnson, R.F., Kessler, D.A., Moses, A. Deep Learning for Scalable Chemical Kinetics // Proceedings of the AIAA Scitech 2020 Forum, Orlando, FL, USA, 6–10 January 2020. P. 0181.
3. Weiqi Ji, Sili Deng. KiNet: A Deep Neural Network Representation of Chemical Kinetics // <https://arxiv.org/abs/2108.00455>, 2021.
4. GRI-Mech Version 3.0 7/30/99 CHEMKINII format, at http://www.me.berkeley.edu/gri_mech/.
5. Nikitin V.F., Karandashev I.M., Malsagov M. Yu, Mikhilchenko E.V. Approach to combustion calculation using neural network // Acta Astronautica. 2022. V. 194. P. 376-382.
6. Мальсагов М.Ю., Михальченко Е.В., Карандашев Я.М., Никитин В.Ф. Применение архитектуры UNET в задаче горения водорода с кислородом // «Нейроинформатика-2021» : сборник научных трудов. Москва : МИФИ, 2021. С. 206-215.

**Б.В. КРЫЖАНОВСКИЙ, Л.Б. ЛИТИНСКИЙ,
И.М. КАГАНОВА**

Федеральный научный центр Научно-исследовательский институт системных исследований Российской академии наук, Москва
kryzhanov@mail.ru, litin@mail.ru, imkaganova@gmail.com

**ТЕРМОДИНАМИКА ВЗАИМОДЕЙСТВИЯ ДВУХ
ОДНОРОДНЫХ ГРУПП БИНАРНЫХ АГЕНТОВ***

Ранее было изучено множество неподвижных точек нейронной сети, матрица связи которой блочно-постоянна, с двумя блоками вдоль главной диагонали. Такая матрица отвечает взаимодействию между двумя группами однородных агентов (спинов, нейронов и т.д.). В настоящей работе изучаются термодинамические характеристики такой системы и их зависимость от внешних параметров задачи.

Ключевые слова: бимодальная коалиция, однородная группа агентов, нейронные сети, термодинамические характеристики.

Введение

Авторами [1, 2] была предложена АВ-модель, которая формализует задачу отыскания бимодальной коалиции – наилучшего разбиения N связанных между собой бинарных агентов на две конкурирующие группы. Связи между агентами задаются симметричной матрицей $\mathbf{J} = (J_{ij})$ с нулевой диагональю. В первоначальной постановке формирование бимодальной коалиции описывалось в терминах максимизации «выгодности» разбиения и определялось в наглядных терминах. В конце 90-х годов S. Galam переформулировал АВ-модель таким образом, что оказалось возможным применить формализм модели Изинга [3, 4]. В новой формулировке каждому разбиению совокупности агентов на две группы сопоставляется N -мерный конфигурационный вектор $\mathbf{s} = (s_1, s_2, \dots, s_N)$ с координатами $s_i = \pm 1$. С помощью матрицы $\mathbf{J}$ каждому конфигурационному

* Настоящая работа выполнена в рамках государственного задания по проведению фундаментальных научных исследований по теме "Исследование нейроморфных систем обработки больших данных и технологии их изготовления" № FNEF-2022-0003.

состоянию сопоставляется энергия $E(\mathbf{s}) \sim -\sum_{i,j=1}^N J_{ij} s_i s_j$. Тогда введенная ранее «выгодность» разбиения эквивалентна взятой с обратным знаком энергии $E(\mathbf{s})$ конфигурации $\mathbf{s}$. Этим проблема сводится к отысканию основного состояния спиновой системы – конфигурации, являющейся глобальным минимумом по энергии. Небольшая модификация построений S. Galam позволила сформулировать задачу в терминах 0-температурной динамики нейронной сети типа модели Хопфилда [5]. Задача свелась к отысканию неподвижных точек нейронной сети – все они являются минимумами по энергии. Мы будем пользоваться термином «бинарные агенты» наравне с физическим термином «спины».

Группа агентов называется *однородной*, если все попарные взаимодействия между агентами одинаковы. В работе [5] было изучено множество неподвижных точек нейронной сети, матрица связи которой стилизована под наличие в материале двух однородных групп агентов с различными константами взаимодействия.

Более конкретно, матрица связи симметрична и устроена следующим образом:

- попарные взаимодействия между N_1 агентами первой группы одинаковы и равны A_1 ;
- аналогично, одинаковы и равны A_2 попарные взаимодействия между N_2 агентами второй группы;
- каждый агент из первой группы одинаково взаимодействует с любым агентом из второй группы – обозначим эту константу A_{12} .

На диагонали матрицы связи стоят нули:

$$\mathbf{J} = \left(\underbrace{\begin{pmatrix} 0 & A_1 & \cdots & A_1 \\ A_1 & 0 & A_1 & \vdots \\ \vdots & A_1 & \ddots & A_1 \\ A_1 & \cdots & A_1 & 0 \end{pmatrix}}_{N_1} \quad \underbrace{\begin{pmatrix} A_{12} & A_{12} & \cdots & A_{12} \\ A_{12} & A_{12} & \cdots & A_{12} \\ \vdots & \vdots & \ddots & \vdots \\ A_{12} & A_{12} & \cdots & A_{12} \end{pmatrix}}_{N_2} \right) \quad (1)$$

Помимо трех констант связи, внешними параметрами задачи являются размеры однородных групп N_1 и N_2 ($N_1 + N_2 = N$).

В [5] было изучено множество неподвижных точек нейронной сети с матрицей связи (1). Удалось построить фазовый портрет системы – описать зависимость множества неподвижных точек от внешних параметров задачи. Фазовый портрет оказался достаточно разнообразным и интересным. Некоторые из полученных результатов допускают правдоподобную интерпретацию в терминах взаимодействия двух конкурирующих групп агентов.

В настоящей работе мы вводим в рассмотрение температуру T и изучаем термодинамику спиновой системы с матрицей связи (1). В первую очередь нас интересует свободная энергия системы $f(\beta)$, где β есть обратная температура: $\beta = 1/T$. Вычислив свободную энергию, мы получаем температурную зависимость намагниченности $m(\beta)$, внутренней энергии $U(\beta)$ и теплоемкости $C(\beta)$, а также отыскиваем критическое значение обратной температуры, при котором в системе происходит фазовый переход.

В следующем разделе мы опишем метод исследования термодинамических характеристик спиновой системы с матрицей связи (1) и получим систему уравнений состояния. В третьем разделе мы опишем новые (необычные) термодинамические характеристики такой спиновой системы, вытекающие из результатов предыдущего раздела. В последнем разделе будет охарактеризована область применения полученных результатов.

Термодинамика системы двух взаимодействующих однородных групп

Формальные результаты. Для правильной нормировки выражений введем новые константы взаимодействия a_1 , a_2 и a_{12} :

$$A_1 = \frac{qa_1}{2N}, \quad A_2 = \frac{qa_2}{2N}, \quad A_{12} = \frac{qa_{12}}{2N}.$$

Параметр q введен для удобства: если положить $a_1 = a_2 = a_{12} = 1$, мы совпадем с моделью среднего поля [6], с которой естественно сопоставлять полученные результаты.

В отсутствие внешнего магнитного поля, энергия, приходящаяся на один спин, равна

$$E(\mathbf{s}) = -\frac{q}{2} (a_1 p_1^2 m_1^2 + 2a_{12} p_1 p_2 m_1 m_2 + a_2 p_2^2 m_2^2), \quad (2)$$

где

$$p_1 = \frac{N_1}{N}, p_2 = \frac{N_2}{N}, m_1 = \frac{\sum_{i=1}^{N_1} s_i}{N_1} = 1 - \frac{2k_1}{N_1}, m_2 = \frac{\sum_{j=1}^{N_1+N_2} s_j}{N_2} = 1 - \frac{2k_2}{N_2}. \quad (3)$$

Здесь k_1 (k_2) – число отрицательных спинов в 1-й (2-й) группе, а m_1 , $m_2 \in [-1, 1]$ – *парциальные* намагниченности. Вообще говоря, обычно в рассмотрениях используют полную намагниченность состояния $\mathbf{s}$

$$m = p_1 m_1 + p_2 m_2 = 1 - \frac{2k}{N}, \quad (4)$$

однако специфика системы (1) заставляет нас следить за парциальными намагниченностями. Как обычно, преобразуем статистическую сумму в интеграл

$$Z = \sum_{k_1=1}^{N_1} \sum_{k_2=1}^{N_2} C_{N_1}^{k_1} C_{N_2}^{k_2} e^{-\beta N E(k_1, k_2)} \sim \int_{-1}^1 dm_1 \int_{-1}^1 dm_2 e^{-N F(m_1, m_2)},$$

где

$$F(\beta, m_1, m_2) = p_1 S(m_1) + p_2 S(m_2) - \frac{\beta q}{2} (a_1 p_1^2 m_1^2 + 2a_{12} p_1 p_2 m_1 m_2 + a_2 p_2^2 m_2^2), \quad (5)$$

а $S(m) = -\ln 2 + \frac{\ln(1-m^2)}{2} + \frac{m}{2} \ln \frac{1+m}{1-m}$ – функция Шеннона [7]. Значение свободной энергии $f(\beta)$ весьма просто связано с минимумом функции $F(\beta, m_1, m_2)$:

$$f(\beta)\beta = \min_{m_1, m_2} F(\beta, m_1, m_2).$$

Дифференцируя $F(\beta, m_1, m_2)$, получаем систему *уравнений состояния*:

$$\begin{aligned} \frac{1}{2} \ln \frac{1+m_1}{1-m_1} &= q\beta (a_1 p_1 m_1 + a_{12} p_2 m_2), \\ \frac{1}{2} \ln \frac{1+m_2}{1-m_2} &= q\beta (a_{12} p_1 m_1 + a_2 p_2 m_2), \end{aligned} \quad (6)$$

решая которую, можем найти значение $f(\beta)$ для каждого β . Аналитического выражения для $f(\beta)$ не существует, однако численно легко постро-

ить график $f(\beta)$, а затем вычислить главнейшие термодинамические характеристики – внутреннюю энергию $U(\beta)$ и теплоемкость $C(\beta)$:

$$U(\beta) = \frac{d(f(\beta)\beta)}{d\beta}, C(\beta) = -\frac{d^2(f(\beta)\beta)}{d\beta^2}. \quad (7)$$

Для отыскания критической температуры β_c с помощью системы уравнений (6) можно получить квадратное уравнение

$$x^2 - x(a_1 p_1 + a_2 p_2) - (a_{12}^2 - a_1 a_2) p_1 p_2 = 0, \text{ где } x = \frac{1}{q\beta}. \quad (8)$$

Из двух корней уравнения (8) необходимо брать наибольший положительный корень, что дает:

$$\beta_c = \frac{2}{q \left(a_1 p_1 + a_2 p_2 + \sqrt{(a_1 p_1 - a_2 p_2)^2 + 4a_{12}^2 p_1 p_2} \right)}. \quad (9)$$

При таком значении температуры происходит фазовый переход второго рода с конечным скачком теплоемкости. Когда все константы a_1, a_2, a_{12} равны 1, выражение (9) переходит в хорошо известный результат для модели среднего поля: $\beta_c^{(MF)} = 1/q$.

Обсуждение полученных результатов

Спиновая система с матрицей связи (1) составлена из двух обособленных систем, и при малой величине a_{12} эти подсистемы являются слабо связанными. Естественнo ожидать, что при малом a_{12} в системе будут наблюдаться два фазовых перехода: один – связанный с первой спиновой подсистемой, и второй – «происходящий» от второй подсистемы. Оказалось, что все совсем не так: даже при малых (по модулю) значениях a_{12} фазовый переход происходит одновременно в обеих спиновых подсистемах. Этот результат можно получить аналитически (см., например, выражение (8) для единственного значения β_c).

На четырех панелях рис. 1 показаны результаты компьютерного расчета термодинамических характеристик спиновой системы с параметрами:

$$q = 4, a_1 = 0.5, a_2 = 1, p_1 = p_2 = 0.5, a_{12} = 0.1. \quad (10)$$

На верхней левой панели приведены графики (безразмерной) свободной энергии $f(\beta)\beta$, на нижней левой панели – графики намагниченности

$m(\beta)$. На верхней правой панели показаны графики внутренней энергии $U(\beta)$, а на нижней правой панели – графики теплоемкости $C(\beta)$.

Сплошными линиями всюду показаны графики, относящиеся к спиновой системе (1) (на нижней левой панели для парциальных намагниченностей $m_1(\beta)$ и $m_2(\beta)$ используются штрихпунктирная и точечная линии соответственно). На тех же панелях штриховыми линиями показаны аналогичные графики для модели среднего поля с $q = 4$: если в (10) положить $a_1 = a_2 = a_{12} = 1$, получим этот вариант модели среднего поля.




Рис. 1. Термодинамические характеристики спиновой системы (10), состоящей из двух однородных групп (сплошная линия), и для модели среднего поля с $q = 4$ (штриховая линия) – см. пояснения в тексте

Графики на нижней левой панели показывают: пока значение β сравнительно невелико, минимум функции (5) находится в точке $m_1 = m_2 = 0$. Так и должно быть, поскольку при высоких температурах T основное состояние характеризуется нулевой намагниченностью: $m(\beta) = 0$. Когда β переваливает через критическое значение $\beta_c = 0.49055$ (9), обе парциальные намагниченности одновременно становятся отличными от нуля: фазовый переход затрагивает не какую-нибудь одну подсистему, а всю спиновую систему целиком. В противном случае в критической точке β_c

только одна из двух парциальных намагниченностей стала бы отличаться от 0, а другая по-прежнему оставалась бы равной 0.

Графики на остальных панелях рисунка демонстрируют типичное средне-полевое поведение. Свободная энергия $f(\beta)\beta$ на левой верхней панели вплоть до β_c равна константе $-\ln 2$, после чего плавно убывает. На графике внутренней энергии $U(\beta)$ (верхняя правая панель) при $\beta = \beta_c$ имеется угловая точка, а у теплоемкости (нижняя правая панель) в этой точке имеется конечный скачок.

Отметим еще несколько результатов, связанных с неочевидным свойством симметрии системы уравнений (6). Справедливо следующее:

Утверждение. Пусть для заданного набора внешних параметров получены функции $m_1(\beta)$ и $m_2(\beta)$ и, как следствие, вычислены $f(\beta)$, $U(\beta)$ и $C(\beta)$. Если в системе уравнений (6) заменить знак межгруппового взаимодействия на противоположный: $\tilde{a}_{12} = -a_{12}$, то:

1) решением новой системы уравнений (6) будет пара функций

$$\tilde{m}_1(\beta) = m_1(\beta), \quad \tilde{m}_2(\beta) = -m_2(\beta);$$

2) все остальные функции останутся неизменными: $\tilde{f}(\beta) \equiv f(\beta)$,

$$\tilde{U}(\beta) \equiv U(\beta), \quad \tilde{C}(\beta) \equiv C(\beta).$$

Первая часть Утверждения проверяется непосредственной подстановкой в систему уравнений (6), а вторая часть следует из сохранения знака у произведения $a_{12}m_2(\beta)$ при обращении знака перекрестного взаимодействия a_{12} .

Из Утверждения следует, что (для рассматриваемого класса матриц связи) всегда существует не одна, а, по меньшей мере, две различные спиновые системы, различающиеся противоположными по знаку константами межгруппового взаимодействия a_{12} и обладающие одним и тем же набором термодинамических характеристик (кроме намагниченности). Это совершенно новое (и необычное) свойство спиновой системы, содержательное осмысление которого предстоит отыскать в конкретных приложениях.

Обратим внимание на еще один неочевидный результат. Пусть спиновая система состоит из двух одинаковых подсистем, так что $p_1 = p_2$ и $a_1 = a_2$. Легко проверяется, что при любом положительном значении $a_{12} > 0$ парциальные намагниченности будут совпадать: $m_1(\beta) \equiv m_2(\beta)$.

Учитывая сказанное выше, получаем: если обратить знак u перекрестного взаимодействия и перейти к спиновой системе с $\tilde{a}_{12} = -a_{12}$, получим $\tilde{m}_2(\beta) = -m_1(\beta)$, и суммарная намагниченность (4) новой системы $\tilde{m}(\beta) = p_1 \tilde{m}_1(\beta) + p_2 \tilde{m}_2(\beta)$ будет тождественно равна 0. В то же время, при $\beta = \beta_c = 2 / q(a_1 + |a_{12}|)$ в спиновой системе происходит фазовый переход второго рода с конечным скачком теплоемкости. Этот результат разрушает общепринятое представление о том, что индикатором фазового перехода является такое значение β , при котором намагниченность становится отличной от нуля: оказывается, фазовый переход может происходить и при $m(\beta) \equiv 0$.

Обсуждение и выводы

Исследованы термодинамические характеристики системы бинарных агентов с матрицей связи, отвечающей наличию в материале двух однородных групп агентов. Предполагается, что взаимодействие между агентами, относящимися к каждой из двух групп, одинаково. Кроме того, перекрестное взаимодействие между агентами разных групп тоже одинаково и задается третьей константой.

Под бинарными агентами понимаются любые элементарные объекты, которые могут находиться в одном из двух состояний. Эти состояния мы описываем спиновой переменной $s_i = \pm 1$, $i = 1, 2, \dots, N$, $N \gg 1$.

Изученные в работе термодинамические свойства напрямую относятся к спиновым системам. Полученные результаты носят отчетливо выраженный средне-полевой характер и обобщают результаты, известные для модели среднего поля [6].

Однако моделью Изинга не исчерпывается область приложения наших рассуждений. Сама модель Изинга находит применение в общественно-социальных исследованиях – от изучения социальных аспектов поведения больших человеческих коллективов до экономических моделей. Мы планируем применить полученные результаты в этих отраслях знания.

Список литературы

1. Axelrod R.M., Bennett D.S. A Landscape Theory of Aggregation // Brit. J. of Polit. Sci. 1993. V. 23, N 2. P. 211-233.
2. Axelrod R.M., [et al.]. Coalition Formation in Standard-Setting Alliances // Management Science. 1995. V. 41, N 9. P. 1493-1508.

3. Galam S. Fragmentation versus stability in bimodal coalitions // *Physica A*. 1996. V. 230. N 1–2. P. 174–188.
4. Galam Serge. *Sociophysics*. NY : Springer-Verlag. 2012. 270 p.
5. Litinskii L., Kaganowa I. Bimodal Coalitions and Neural Networks // Kryzhanovsky B. [et al.]. (eds). *Advances in Neural Computation, Machine Learning, and Cognitive Research III* // *NEUROINFORMATICS 2019. Studies in Computational Intelligence*. Berlin: Springer, Cham. 2020. V. 856. P. 412–419.
6. Бэкстер Р. Точно решаемые модели в статистической механике. Москва : Мир. 1985.
7. Litinskii L., Kryzhanovsky B. Spectral density and calculation of free energy // *Physica A*. 2018. V. 510. P. 702–712.

НЕЙРОМОРФНЫЕ ВЫЧИСЛЕНИЯ, ГЛУБОКОЕ ОБУЧЕНИЕ

Д.И. АНТОНОВ^{1,2}, С.В. СУХОВ¹

¹Институт радиотехники и электроники имени В.А. Котельникова РАН
(Ульяновский филиал)

²Ульяновский государственный технический университет
d.antonov@ulireran.ru

МЕХАНИЗМЫ ПРЕДОТВРАЩЕНИЯ КАТАСТРОФИЧЕСКОГО ЗАБЫВАНИЯ В ИМПУЛЬСНЫХ НЕЙРОННЫХ СЕТЯХ*

При последовательном обучении искусственные нейронные сети испытывают катастрофическое забывание (КЗ). Особенности импульсных нейронных сетей (ИмНС) предоставляют дополнительные механизмы для борьбы с КЗ. В данной работе мы исследовали эффект латерального торможения и учет важности нейронов в ИмНС для КЗ. Эксперименты были выполнены на общедоступных наборах данных в окружении SpykeTorch.

Ключевые слова: катастрофическое забывание, импульсные нейронные сети, нейроморфные вычисления, латеральное торможение.

Введение

Импульсные (спайковые) нейронные сети (ИмНС) являются новым поколением искусственных нейронных сетей. Интерес к этим сетям обусловлен, с одной стороны, возможностью моделирования с помощью этих сетей динамики нейронных сетей мозга. С другой стороны, ИмНС могут служить основой для организации вычислительного процесса в перспективном нейроморфном оборудовании [1].

По сравнению с биологическими нейронными сетями искусственные нейронные сети обладают некоторыми недостатками. В частности, аналоговые нейронные сети испытывают катастрофическое забывание (КЗ) при последовательном обучении. Методы, позволяющие обеспечить непрерывное обучение нейронной сети без повреждения ранее приобретенного знания, насушно необходимы [2, 3]. Отличие ИмНС от аналоговых сетей в плане кодирования информации и обучения предоставляет новые меха-

* Данная работа выполнена при поддержке РФФИ, проект № 20-07-00974.

низмы для предотвращения КЗ. В данной работе мы рассматриваем особенности предотвращения КЗ при обучении ИмНС с помощью локальных правил и при наличии латерального нейронального торможения.

Проблема предотвращения катастрофического забывания в *аналоговых* нейронных сетях является активной областью исследований. В то же время исследованию этой проблемы в импульсных сетях посвящено всего несколько работ. Некоторые работы рассматривают гибридные сети, состоящие из спайковой подсети, предназначенной для выделения признаков, и аналогового классификатора [4]. Для предотвращения катастрофического забывания при этом используется метод синаптического интеллекта [5], однако этот метод применяется только к аналоговой части. Для предотвращения КЗ в работе [6] авторы чередовали процесс обучения с периодом «сна». Во время «сна» авторы заменяли механизм обучения с подкреплением во внешнем слое на обучение без учителя. Авторы работы [7] показали, что в рекуррентных ИмНС память может быть стабилизирована определенным классом пластичности, зависящей от времени спайка (spike-time dependent plasticity, STDP).

В нашей статье мы рассматриваем импульсные нейронные сети без каких-либо аналоговых дополнений. ИмНС в нашей работе обучаются без обратного распространения ошибки только на основе локальных правил. Мы протестировали несколько методов предотвращения КЗ специфичных для ИмНС. При этом мы разработали оригинальный метод определения важности весов в ИмНС, что является необходимым для сохранения предыдущего знания при последовательном обучении.

Постановка задачи и описание алгоритма

На первом этапе импульсная нейронная сеть обучалась на определенном наборе данных. В соответствии со стандартной постановкой задачи последовательного обучения, мы считаем, что после первоначального обучения тренировочные данные более недоступны. Необходимо, чтобы обучение сети на новых данных не привело к забыванию старых.

В данной работе мы рассматриваем подходы по предотвращению катастрофического забывания, основанные на особенностях ИмНС: присутствие латерального торможения между нейронами и локальные правила обучения.

Уже в первых работах [8], посвященных проблеме катастрофического забывания, предполагалось, что забывание может быть обусловлено перекрытием картин активностей нейронов для прежних и новых данных. Уменьшая это перекрытие, можно избежать нежелательной интерферен-

ции активностей при последовательном обучении. Интерференцию можно уменьшить путем создания разреженной нейрональной активности. Одним из механизмов, обеспечивающим разреженную активность, является латеральное торможение (lateral inhibition). В нейробиологии латеральное торможение описывает процесс подавления наиболее активным нейроном активностей своих более слабых соседей. В нашей работе исследовано влияние латерального торможения на подавление катастрофического забывания в ИмНС.

Другой распространенный способ предотвращения катастрофического забывания основан на определении важности весов [9]: значения наиболее важных весов при последовательном обучении должны изменяться в меньшей степени, что должно привести к меньшему забыванию прежней информации. Использование данного подхода в ИмНС имеет свои особенности. Локальные правила обучения ИмНС подразумевают отсутствие глобальной функции потерь и невозможность расчета градиентов. Это препятствует использованию многих методов определения важности весов, разработанных для аналоговых сетей. В нашей работе мы разработали оригинальный метод, связывающий важность того или иного веса с приемлемой областью его изменения. Область приемлемого изменения веса определялась с помощью динамики Ланжевена в пространстве весов. Алгоритм предотвращения катастрофического забывания выглядит следующим образом.

На первом этапе ИмНС обучается на начальном наборе данных обычным образом.

На втором этапе реализовывалась броуновская динамика в пространстве весов путем добавления к значениям весов гауссова шума:

$$\Delta w_{ij} = F(w_{ij}) + \sigma N(0, 1). \quad (1)$$

Δw_{ij} в уравнении (1) определяет величину изменения синаптической связи между двумя нейронами с индексами i и j . Индексы i и j относятся к пост- и пресинаптическим нейронам соответственно; $N(0, 1)$ – стандартное нормальное распределение, σ определяет амплитуду гауссова шума.

Уравнение (1) представляет собой демпфированное уравнение Ланжевена, в котором значения весов w_{ij} являются координатами виртуальной частицы в пространстве весов. Эффективная «сила» $F(w_{ij})$ (будет определена в следующем разделе) обусловлена STDP-механизмом. «Сила» $F(w_{ij})$ пытается вернуть значения весов к их оптимальному значению.

При достаточно продолжительном времени случайного блуждания траектория броуновского движения может покрыть практически всю область допустимых значений весов. В экспериментах мы обычно ограничивали процесс броуновского движения определенным числом шагов. Последовательные значения всех весов сети в данном процессе сохранялись в отдельный массив.

Амплитуду шума σ необходимо выбирать на основе компромисса между необходимостью покрыть с помощью броуновского движения как можно большую площадь и способностью STDP-процесса возвращать веса к оптимальному значению.

На третьем этапе на основе траекторий стохастического блуждания весов делалось заключение о возможном диапазоне изменения того или иного веса. Этот процесс аналогичен оценке вероятностного распределения весов в байесовских нейронных сетях [10]. На практике для каждого веса w_{ij} из сохраненного массива мы строили его вероятностное распределение $p(w_{ij})$ и определяли нижнюю w_{ij}^l и верхнюю w_{ij}^u границы распределения. Размер диапазона $[w_{ij}^l, w_{ij}^u]$ имеет непосредственное отношение к важности веса: чем уже этот диапазон, тем более важен вес.

На четвертом этапе при обучении ИмНС на новом наборе данных каждому из весов w_{ij} позволялось меняться только в диапазоне $[w_{ij}^l, w_{ij}^u]$. Ограничение изменения важных весов должно помочь в преодолении катастрофического забывания.

Импульсная нейронная сеть

В наших экспериментах мы использовали сверточную импульсную нейронную сеть-классификатор. ИмНС была реализована на основе библиотеки SpykeTorch [11]. Нейроны, составляющие нейронную сеть, моделировались интегрирующими (integrate-and-fire) нейронами без утечки. При прохождении сигнала каждый нейрон генерировал не более одного импульса. Информация в SpykeTorch кодировалась временем прихода спайка. Обучение нейронной сети осуществлялось локальными правилами, основанными на вариациях STDP-механизма. Веса в скрытых слоях обучались без учителя. Веса в выходном слое обучались с подкреплением (R-STDP). Изменение весов на одном шаге обучения можно описать следующей общей формулой [12]:

$$\Delta w_{ij} = F(w_{ij}) = \delta_{ij} (w_{ij} - w_{\min})(w_{\max} - w_{ij}), \quad (2)$$

$$\delta_{ij} = \begin{cases} \alpha \phi_r a_r^+ + \beta \phi_p a_p^-, & \text{если } t_j - t_i \leq 0, \\ \alpha \phi_r a_r^- + \beta \phi_p a_p^+, & \text{если } t_j - t_i > 0. \end{cases} \quad (3)$$

Произведение $(w_{ij} - w_{\min})(w_{\max} - w_{ij})$ в уравнении (2) нужно для стабилизации обучения. Наличие этого множителя не позволяет значениям весов выходить за нижнюю $w_{\min}$ и верхнюю $w_{\max}$ границы. Коэффициенты a_r^+ , a_r^- , a_p^+ , a_p^- масштабируют величину изменения веса. Правило (3) описывает упрощенный механизм STDP, который учитывает только знак разницы времен прихода импульсов. В случае обычного механизма STDP $\phi_r = 1$, $\phi_p = 0$, $\alpha = 1$, $\beta = 0$. В случае R-STDP значения коэффициентов α и β определяются сигналом подкрепления. Если генерируется сигнал поощрения (правильная классификация объекта сетью), то $\alpha = 1$, $\beta = 0$; в случае сигнала наказания (неправильная классификация) $\alpha = 0$, $\beta = 1$. Кроме того, $\phi_r = N_{\text{miss}} / N$, $\phi_p = N_{\text{hit}} / N$, где N_{hit} и N_{miss} – число образцов, классифицированных правильно и неправильно соответственно. Правила обучения (2), (3) применяются для каждого входного образца; параметры ϕ_r и ϕ_p обновляются для каждого пакета (batch) образцов.

Архитектура нейронной сети, использованной в наших экспериментах, совпадает с архитектурой, описанной в работе [11]. В частности, сеть состоит из трех сверточных слоев (S1, S2, S3); каждый слой содержит несколько двумерных площадок интегрирующих нейронов. Эти площадки служат для выделения отдельных признаков на входных образцах. После каждого из сверточных слоев следует слой подвыборки (pooling layer). Выходной слой состоит из 200 нейронов, по 20 нейронов на класс.

Каждый из входящих образцов проходил через операцию свертки с фильтрами разности гауссиан (difference of Gaussian, DoG). После обработки образцов фильтрами DoG создавалась череда импульсов (спайков) путем преобразования интенсивности в задержку спайка по времени [13]. Спайковая активность распространялась по сети до слоя выходных нейронов. Согласно схеме кодирования в соответствии с рангом (rank-order coding) нейрон, сгенерировавший самый ранний импульс, или нейрон, обладающий наибольшим потенциалом, отображал решение сети. Мы использовали параметры обучения сети, аналогичные параметрам в работе [14].

Для последовательного обучения сети было использовано два набора данных. Для первоначального обучения использовался набор изображений рукописных цифр MNIST [15]. Для последующего обучения ИмНС использовалась часть набора EMNIST [16], содержащая 10 классов изображений рукописных букв латинского алфавита (буквы A, B, D, E, G, H, N, Q, R, S). Для получения сбалансированного обучающего набора мы использовали по 24 000 элементов из наборов MNIST и EMNIST.

Численные эксперименты

Латеральное торможение. В этом разделе мы исследуем влияние латерального торможения на катастрофическое забывание в ИмНС. На первом шаге ИмНС обучалась на наборе MNIST (Задача 1). В соответствии с идеей работы [12] ИмНС обучалась послойно. Сверточные слои S1 и S2 обучались с помощью алгоритма STDP в течение двух и четырех эпох, соответственно. Последний слой S3 обучался в течение 50 эпох с помощью R-STDP. Обучение проводилось при различном значении радиуса латерального торможения (R_1 , R_2 , R_3) в каждом из трех сверточных слоев. Конечная точность классификации оценивалась на тестовом наборе данных, состоящем из 4000 образцов. Точность классификации в Задаче 1 составляла 91...95% (табл. 1). Такая относительно невысокая точность была обусловлена частичным использованием набора MNIST и малым числом эпох обучения (из-за экономии времени). Для сравнения, при обучении ИмНС на полном наборе MNIST в течение 686 эпох точность классификации составляет 97% [12].

Таблица 1

Точность распознавания изображений в серии опытов с изменяющимися радиусами латерального торможения

Радиусы латерального торможения			Точность распознавания, %		
R1	R2	R3	Задача 1 (MNIST)	Задача 2 (EMNIST)	Задача 2 (MNIST)
0	0	0	90,8	78,4	48,1
3	1	0	93,6	87,3	73,3
5	1	0	94,8	86,5	72,2
5	2	0	94,8	88,9	78,6

На втором шаге (Задача 2) сверточные слои S1 и S2 предобученной ИмНС обучались на наборе EMNIST в течение двух и четырех эпох соответственно; выходной слой S3 обучался в течение 100 эпох. Результаты экспериментов показаны в табл. 1. Можно видеть, что в отсутствие латерального торможения (нулевой радиус во всех слоях) ИмНС испытывает значительное катастрофическое забывание – точность классификации набора MNIST существенно падает. При увеличении радиуса латерального торможения точность классификации предыдущих данных существенно улучшается.

Обучение при учете важности весов. Здесь мы исследуем эффект учета важности весов на катастрофическое забывание в ИмНС. На первом шаге мы обучили ИмНС на наборе MNIST. Как и в предыдущих экспериментах сверточные слои S1 и S2 обучались в течение двух и четырех эпох, соответственно; слой S3 обучался в течение 50 эпох. После первоначального обучения мы стали добавлять к весам гауссов шум на каждом шаге обучения для реализации броуновской динамики. В качестве амплитуды шума было выбрано значение $\sigma = 4 \cdot 10^{-4}$. Обучение с шумом продолжалось до тех пор, пока точность классификации набора MNIST не падала до уровня 80%. Падение точности происходило из-за того, что механизм R-STDP не мог вполне противостоять такому уровню шума. В то же время меньшая амплитуда шума привела бы к слишком медленной диффузии весов.

После завершения броуновского блуждания мы рассчитали функцию распределения вероятности $p(w_{ij})$ для каждого веса. Типичная траектория блуждания веса и соответствующее распределение вероятности показаны на рис. 1.

На основе распределения $p(w_{ij})$ мы определили диапазон изменения для каждого веса $[w_{ij}^l, w_{ij}^u]$. В качестве нижней и верхней границ были использованы либо первый Q1 и третий Q3 квантили распределения вероятностей, либо первый D10 и девятый D90 децили (рис. 1). На следующем шаге мы выполнили обучение ИмНС на наборе EMNIST (Задача 2), позволяя весам изменяться только в пределах найденных диапазонов. Конечная точность классификации для наборов MNIST и EMNIST при различных критериях выбора диапазона $[w_{ij}^l, w_{ij}^u]$ показана в табл. 2.




Рис. 1. Динамика значений случайно выбранного веса в течение обучения с шумом. На гистограмме, расположенной справа, отображено распределение вероятностей веса и указаны децили D10 и D90

Таблица 2

Точность распознавания изображений в серии опытов с определением важности весов

Нижняя и верхняя границы интервала	Точность распознавания на Задаче 2, %	
	EMNIST	MNIST
Q1 (25%) и Q3 (75%)	66,3	78,7
D10 (10%) и D90 (90%)	78,3	82,2

Из таблицы можно видеть, что существуют оптимальные критерии выбора диапазона $[w_{ij}^l, w_{ij}^u]$, которые, с одной стороны, не позволяют забываться предыдущему знанию, а с другой стороны, не препятствуют приобретению сетью нового знания.

Заключение

Мы рассмотрели специфичные для импульсных нейронных сетей механизмы предотвращения катастрофического забывания при последова-

тельном обучении. Рис. 2 подытоживает результаты нашего исследования. Присутствие катастрофического забывания в ИмНС (рис. 2а) говорит о том, что кодирование информации спайками само по себе не решает проблему КЗ. Идеальным вариантом обучения было бы совместное обучение на обоих наборах данных (MNIST и EMNIST) (рис. 2б). В отсутствие предыдущих обучающих данных латеральное торможение в значительной степени устраняет катастрофическое забывание (рис. 2в). Ограничение изменения весов (рис. 2г) сохраняет предыдущее знание в сети, но в некоторой степени препятствует обучению на новых данных.




Рис. 2. Точность классификации набора MNIST (пунктирная линия) и EMNIST (сплошная линия) в процессе обучения Задаче 2 в случае (а) катастрофического забывания, (б) совместного обучения на двух наборах данных, (в) латерального торможения, (г) учета важности весов

Список литературы

1. Roy K., Jaiswal A., Panda P. Towards spike-based machine intelligence with neuromorphic computing // Nature. 2019. V. 575, N 7784. P. 607-617.

2. Hassabis D., Kumaran D., Summerfield C., Botvinick M. Neuroscience-inspired artificial intelligence // *Neuron*. 2017. V. 95, N 2. P. 245–258.
3. Parisi G.I., Kemker R., Part J.L., Kanan C., Wermter S. Continual lifelong learning with neural networks: A review // *Neural Networks*. 2019. V. 113. P. 54–71.
4. Vaila R., Chiasson J., Saxena V. Continuous Learning in a Single-Incremental-Task Scenario with Spike Features // *International Conference on Neuromorphic Systems*. 2020. P. 1–4.
5. Zenke F., Poole B., Ganguli S. Continual Learning Through Synaptic Intelligence // *International Conference on Machine Learning*. 2017. P. 3987–3995.
6. Golden R., Delanois J.E., Sanda P., Bazhenov M. Sleep prevents catastrophic forgetting in spiking neural networks by forming joint synaptic weight representations // *BioRxiv preprint*. 2020. BioRxiv:688622.
7. Wei Y., Koulakov A.A. Long-term memory stabilized by noise-induced rehearsal // *Journal of Neuroscience*. 2014. V. 34, N 47. P. 15804–15815.
8. French R.M. Catastrophic forgetting in connectionist networks // *Trends in Cognitive Sciences*. 1999. V. 3, N 4. P. 128–135.
9. Kirkpatrick J., Pascanu R., Rabinowitz N., Veness J., Desjardins G., Rusu A.A., Milan K., Quan J., Ramalho T., Grabska-Barwinska A., Hassabis D., Clopath C., Kumaran D., Hadsell R. Overcoming catastrophic forgetting in neural networks // *Proceedings of the National Academy of Sciences*. 2017. V. 114, N 13. P. 3521–3526.
10. Welling M., Teh Y.W. Bayesian learning via stochastic gradient Langevin dynamics // *Proceedings of the 28th international conference on machine learning (ICML-11)*. 2011. P. 681–688.
11. Mozafari M., Ganjtabesh M., Nowzari-Dalini A., Masquelier T. Spyketorch: Efficient simulation of convolutional spiking neural networks with at most one spike per neuron // *Frontiers in Neuroscience*. 2019. V. 13. P. 625.
12. Mozafari M., Ganjtabesh M., Nowzari-Dalini A., Thorpe S. J., Masquelier T. Bio-inspired digit recognition using reward-modulated spike-timing-dependent plasticity in deep convolutional networks // *Pattern Recognition*. 2019. V. 94. P. 87–95.
13. Gautrais J., Thorpe S. Rate coding versus temporal order coding: a theoretical approach // *Biosystems*. 1998. V. 48, N 1–3. P. 57–65.
14. Kheradpisheh S.R., Ganjtabesh M., Thorpe S.J., Masquelier T. STDP-based spiking deep convolutional neural networks for object recognition // *Neural Networks*. 2018. V. 99. P. 56–67.
15. Lecun Y., Bottou L., Bengio Y., Haffner P. Gradient-based learning applied to document recognition // *Proceedings of the IEEE*. 1998. V. 86, N 11. P. 2278–2324.
16. Cohen G., Afshar S., Tapson J., van Schaik A. EMNIST: an extension of MNIST to handwritten letters // *ArXiv Preprint*. 2017. ArXiv:1702.05373.

**В.В. КРАСНИКОВ, А.А. ЧЕЖЕГОВ, И.С. БАЛАШОВ,
А.С. ЧИЖОВ, А.А. ГРУНИН, А.А. ФЕДЯНИН**

Московский государственный университет им. М.В. Ломоносова

krasnikov@nanolab.phys.msu.ru

НЕЙРОМОРФНЫЕ ФОТОЭЛЕКТРИЧЕСКИЕ СИНАПСЫ НА ОСНОВЕ НАНОКРИСТАЛЛИТОВ ОКСИДОВ МЕТАЛЛОВ

В нашей работе сообщается о реализации фотоэлектрического синапса на основе полупроводниковых нанокристаллита (ZnO , In_2O_3 , WO_3). Выбор типа нанокристаллита и выбор параметров изготовления позволяют получать нейроморфные элементы с варьируемыми свойствами. В качестве синаптического сигнала в работе используются импульсы света на длине волны 405 нм. Изменение проводимости при облучении светом изменяет сопротивление на постнейроне.

Ключевые слова: *фотоэлектрический синапс, нейроморфные элементы.*

В настоящее время в современном мире обработка больших данных является одним из основных направлений науки и техники. Для задач распознавания и классификации изображений хорошо подходят искусственные нейронные сети (ИНС). ИНС традиционно поддерживаются классическими электронными компьютерами, построенными на архитектуре фон-Неймана. Такая архитектура подходит для выполнения одной последовательности команд с высокой скоростью. Но в задачах ИНС требуются высоко-параллельные, многопоточные вычисления с возможностью перемещения большого объема данных, по шине данных, между вычислительным процессором и памятью. В многопоточных вычислениях архитектура фон-Неймана из-за конечности размера шины данных, имеет ограничение пропускной способности (узкое место), что приводит к ограничениям скорости в задачах обучения и распознавания [1, 2]. Одним из возможных путей будущей вычислительной парадигмы является переход к нейроморфным фотоэлектрическим схемам, вдохновленных мозгом.

Искусственный синапс является одним из основных элементов нейроморфного компьютера. Синапс осуществляет контакт между пренейроном и постнейроном [3]. Биологический синапс обладает свойствами синаптической пластичности, которые приводят к возникновению кратковремен-

ной памяти (STM) и долговременной памяти (LTM) и отвечает за процессы обучения нейронов [4].

В данной работе сообщается о фотоэлектрическом синапсе на основе нанокристаллитов полупроводников (ZnO , In_2O_3 , TiO_2 , WO_3). Подход к созданию искусственного синапса дешев и прост в реализации. Выбор типа нанокристаллита и выбор параметров изготовления позволяют получить нейроморфные элементы с различными характеристиками. Световые импульсы длиной волны 405 нм используются в качестве предварительного нейронного сигнала для фотоэлектрического синапса. По изменению проводимости при облучении светом измеряли выходной сигнал с пост-нейрона.




Рис. 1. Биологический синапс (слева) и биоинспирированный фотоэлектрический синапс (справа) на основе нанокристаллитной полупроводниковой пленки с составом атмосферного газа и температурой в качестве дополнительных управляющих параметров

Исследованные фотоэлектрические синапсы на основе полупроводниковых нанокристаллитов демонстрируют биологически подобные синаптические свойства пластичности. Было исследовано влияние частоты спайков и правила следования спайков на динамику синаптической пластичности, STM и LTM. Фотоэлектрический синапс продемонстрировал переход от STM к LTM с увеличением частоты спайков, увеличением веса спайка и увеличением количества принятых спайков. Был продемонстрирован базовый способ нейроморфного обучения в виде парно-импульсной фасциляции (PPF индекс) [5].

Перспективен поиск дополнительных управляющих параметров, действующих как нейромодуляторы. Было получено, что для исследованных синапсов состав газов атмосферы и изменение температуры могут играть роль нейромодуляторов. Исследованные фотоэлектрические синапсы на основе ZnO , In_2O_3 , TiO_2 , WO_3 имеют широкий набор параметров, отлича-

ющихся по временным характеристикам STM и LTM. Дополнительные каналы изменения состава газа и температуры, выполняющие роль нейромодуляторов, имеют высокий потенциал для реализации в качестве большого класса компонентов фотоэлектрических нейроморфных схем.

Список литературы

1. Del Valle J. [et al.]. Challenges in materials and devices for resistive-switching-based neuromorphic computing // Journal of Applied Physics. 2018. V. 124, N 21. P. 211101.
2. Nahmias M.A. [et al.]. Neuromorphic photonics // Optics and Photonics News. 2018. V.29, N 1. P. 34-41.
3. Kotseruba I., Tsotsos J.K. 40 years of cognitive architectures: core cognitive abilities and practical applications // Artificial Intelligence Review. 2020. V. 53, N 1. P. 17-94.
4. Lee M. [et al.]. Brain-inspired photonic neuromorphic devices using photodynamic amorphous oxide semiconductors and their persistent photoconductivity // Advanced Materials. 2017. V. 29, N 28. P. 1700951.
5. Hu S. G. [et al.]. Emulating the paired-pulse facilitation of a biological synapse with a NiOx-based memristor // Applied Physics Letters. 2013. V. 102, N 18. P. 183510.

М.М. КРАСНОВ, В.С. СМОЛИН

Федеральный исследовательский центр Институт прикладной математики
им. М.В. Келдыша Российской академии наук, Москва
kmm@kiam.ru, smolin@keldysh.ru

**ИСПОЛЬЗОВАНИЕ ДИФФЕРЕНЦИАЛЬНЫХ СВОЙСТВ
ДЛЯ ПОВЫШЕНИЯ КАЧЕСТВА АППРОКСИМАЦИИ
ФУНКЦИЙ НЕЙРОСЕТАМИ**

Описывается использование ВРЕ (backpropagation error) для аппроксимации функций, заданных не явно, а в виде свойств, описываемых дифференциальным уравнением и начальными значением. Предлагается способ формирования нейросетевых структур для вычисления частных производных аппроксимирующей функции и выводится нелинейное преобразование на основе выбранной исходной нелинейной функции формальных нейронов. В качестве примера приводится уравнение Хопфа.

Ключевые слова: ВРЕ, нейросети, производные, уравнение Хопфа.

Введение

Более 60 лет назад было доказано в [1], необходимая сложность систем для решения «интеллектуальных» задач должна быть не ниже, чем сложность задач, и именно нейросетевые алгоритмы дают средства для эффективной автоматической настройки огромного количества латентных (внутренних) параметров. Это сделало доступной обработку сложных сигналов реального мира на качественно более высоком уровне.

Резкий рост коммерческого использования нейросетевых алгоритмов в устройствах и системах, решающих «интеллектуальные» задачи, произошедший в 2010–2012 гг. принято называть нейросетевой революцией в машинном обучении. За последние 10 лет был достигнут ряд выдающихся результатов в самых разнообразных областях: в распознавании изображений [2] и речи [3], в логических и компьютерных играх [4], генерации изображений, текстов, речи [5] и ведении диалогов и других задач.

Одной из главных компонент достигнутого успеха является совершенствование и развитие метода ВРЕ, авторами которого принято считать [6]. Сам по себе метод ВРЕ не позволяет эффективно решать «интеллектуальные» задачи, но за более чем 30 лет было разработано множество алгоритмов, повышающих его устойчивость и сходимость, таких как батч-

норм, дроп-аут и ряд других, входящих в современные курсы по глубокому обучению нейросетей [7, 8].

По своей сути метод ВРЕ (+ современные алгоритмы) формирует аппроксимацию преобразования вектора входного сигнала в многокомпонентный выход. Для разных классов задач и типов сигналов разработаны и успешно применяются большое количество разнообразных структур нейросетей. Тем не менее лидеры развития теории глубокого обучения отмечают [9], что, несмотря на огромные успехи, имеется и множество проблем развития подходов, основанных на использовании метода ВРЕ.

Данная работа посвящена использованию метода ВРЕ в задачах, в которых нужно аппроксимировать не только значения самого преобразования (входного сигнала в выходной), но и значения частных производных этого преобразования по входным переменным.

Постановка задачи

Такие задачи встречаются, например, когда аппроксимируемая функция неизвестна, а заданы начальные или граничные условия и свойства функции, описываемые в виде дифференциального уравнения. В качестве примера будем рассматривать аппроксимацию уравнения Хопфа [10].

Для получения решения уравнения Хопфа надо найти функцию $u(t, x)$; $t \in \mathbb{R}_+$, $x \in \mathbb{R}$, удовлетворяющую условиям:

$$F(u) = u_t + uu_x = 0, u(0, x) = u_0(x), \quad (1)$$

где $u_0(x) = u_0$ – заданные начальные условия (при $t = 0$).

Активность выходного элемента нейросети будем называть *активностью всей нейросети* и обозначать как $Net(t, x)$ или просто Net , а частные производные Net по x , t – Net_x и Net_t .

Таким образом, выходные переменные нейросети – это Net , Net_x и Net_t . Они не моделируют напрямую значения искомой функции $u(t, x)$, а выбираются такими, чтобы после обучения

$$u(t, x) = u_0(x) + tNet(t, x), \quad (2)$$

что обеспечивает $u = u_0(0, x)$ при любых значениях $Net(0, x)$. Тогда

$$u_x = u'_0 + tNet_x, \quad (3)$$

$$u_t = Net + tNet_t. \quad (4)$$

При этом на основе (2) – (4) функцию Хопфа можно записать через активность выходных элементов сети Net , Net_x и Net_t :

$$\begin{aligned} F(u) &= F(Net) = Net + tNet_t + (u_0 + tNet) \cdot (u'_0 + tNet_x) = \\ &= (1 + tu'_0) \cdot Net + t \cdot Net_t + \\ &+ tu_0 \cdot Net_x + t^2 \cdot Net \cdot Net_x + u_0 u'_0. \end{aligned} \quad (5)$$

Для решения этого уравнения нейросетевым способом мы используем сеть с двумя входами (соответствующие переменным x и t) и одним выходным элементом Net (для активности). Таким образом, $N_0 = 2, N_{M+1} = 1$. Но, поскольку нам нужны ещё значения Net_x и Net_t , выходов у сети должно быть три и данная работа посвящена вопросу, как организовать вычисление Net_x и Net_t и процесс адаптации параметров в модифицированной (с целью вычисления значений частных производных) нейросети.

Описание алгоритма

Возьмём нейросеть с M ($M \geq 1$) скрытыми слоями. На первый скрытый слой подаются два входа – x и t .

Активность (выход) l -го элемента k -го скрытого слоя, $1 \leq k \leq M$, вычисляется по следующей формуле от выходов предыдущего слоя:

$$O^{k,l} = \sigma \left(w_{k,0,l} + \sum_{j=1}^{N_{k-1}} w_{k,j,l} O^{k-1,j} \right); k = 1 \dots M, l = 1 \dots N_k, \quad (6)$$

где N_k – число элементов k -го скрытого слоя ($N_{M+1} = K$), $O^{k-1,j}$ – выходы элементов предыдущего слоя, $w_{k,j,l}$ – веса связей входов (k -й слой, j -я связь l -го элемента), $w_{k,0,l}$ – пороговое значение элемента, σ – функция активации (например, сигмоида или другая функция).

Обозначим вход нейросети как нулевой слой размера $N_0 = 2$.

Положим также, что для любого k :

$$O^{k,0} \equiv 1; 0 \leq k \leq M \quad (7)$$

Тогда линейную активность l -го элемента k -го слоя можно записать так, единообразной суммой (см. рис. 1):

$$A^{k,l} = \sum_{j=0}^{N_{k-1}} w_{k,j,l} O^{k-1,j}; k = 1 \dots M, l = 1 \dots N_k. \quad (8)$$

Соответственно

$$O^{k,l} = \sigma(A^{k,l}); k = 1 \dots M, l = 1 \dots N_k. \quad (9)$$

Для элементов выходного слоя есть варианты. Активность выходного элемента может вычисляться так же, как активность элементов скрытых слоёв, а может совпадать с его линейной активностью:

$$Net = O^{M+1,l} = A^{M+1,l} = \sum_{j=0}^{N_M} w_{M+1,j,l} O^{M,j}. \quad (10)$$




Рис. 1. Схема формального нейрона для аппроксимации функций

Если в аппроксимируемой функции важны не только значения самой целевой функции, но и её производных по параметрам входного сигнала (а у нас именно такой случай – целевая функция задана уравнением в частных производных), то необходимо вычислять и значения этих производных. Введём общее обозначение этих параметров как v . В нашем случае входные переменные x и t могут служить такими параметрами. Соответственно:

$$A_v^{k,l} \equiv \frac{\partial A^{k,l}}{\partial v} = (\sum_{j=0}^{N_{k-1}} w_{k,j,l} O^{k-1,j})_v = \sum_{j=0}^{N_{k-1}} w_{k,j,l} O_v^{k-1,l}; \quad (11)$$

$$O_v^{k,l} = \sigma(A^{k,l})_v = \sigma'(A^{k,l}) A_v^{k,l}. \quad (12)$$

Формулы (11) и (12) являются просто результатом формального дифференцирования формул (8) и (9) по параметру v . Аналогично для (10):

$$Net_v^l = O_v^{M+1,l} = A_v^{M+1,l} = \sum_{j=1}^{N_M} w_{M+1,j,l} O_v^{M,j}. \quad (13)$$

$A_v^{k,l}$ и $O_v^{k,l}$ вычисляются по формулам, похожим на (8) и (9) – тоже суммирование умноженных на те же самые веса связей $w_{k,j,l}$ выходных активностей предыдущего слоя и нелинейное преобразование полученной суммы. Но есть два важных отличия: суммируются не значения выходных активностей $O^{k-1,j}$, а их производные $O_v^{k-1,l}$, и нелинейное преобразование $A_v^{k,l}$ в $O_v^{k,l}$ зависит не только от $A_v^{k,l}$, но и от $A^{k,l}$. Поэтому для вычисления Net_x и Net_t будем использовать нейроподобные элементы с несколько другой структурой (рис. 2, сравните с рис. 1).




Рис. 2. Схема формального нейрона для аппроксимации производных

Введём обозначения для нелинейного преобразования и его производной по аргументу:

$$\sigma_{k,l} \equiv \sigma(A^{k,l}), \quad (14)$$

$$\sigma'_{k,l} \equiv \sigma'(A^{k,l}). \quad (15)$$

Последовательно применяя формулы (8), (9), (11) и (12) к слоям нейросети, можно получить значения выходной активности и её производных последнего скрытого слоя $O^{M,l}$ и $O_v^{M,l}$, а по формулам (10) и (13) – $O^{M+1,l}$ и $O_v^{M+1,l}$. Можно и не выделять входной и выходной слои, а считать, что $O^{0,j} \equiv A^{0,j}$; $\frac{\partial O^{0,j}}{\partial A^{0,j}} \equiv 1$ и $O^{M+1,1} \equiv A^{M+1,1}$, $\frac{\partial O^{M+1,1}}{\partial A^{M+1,1}} \equiv 1$.

Нейросеть состоит из 3-х компонент, рассчитывающих во взаимосвязи Net , Net_x и Net_t (рис. 3). Две выходные активности, Net_x и Net_t , которые тоже рассчитываются нейросетями, имеют совпадающие с исходной сетью веса связей $w_{k,j,l}$ и используют активности элементов скрытых слоёв $A^{k,l}$ по формуле (12). На основе вычисленных производных выходных активностей $O_x^{k,l}$ и $O_t^{k,l}$ на выходе сети и формируются Net_x и Net_t .

При обучении сетей для решения уравнения Хопфа при заданных начальных условиях $u_0(x)$ будем приближать к нулю ошибку в виде

$$E = \frac{1}{2} F(u)^2 = \frac{1}{2} (u_t + uu_x)^2. \quad (16)$$




Рис. 3. Структура нейросети, вычисляющей функцию $Net(x, t)$ и её производные Net_x и Net_t . Сеть состоит из трёх подсетей, имеющих совпадающие структуры и веса связей $w_{k,j,l}$, которые при обучении меняются одновременно во всех трёх подсетях. Кроме того, во второй и третьей подсетях вид нелинейного преобразования является результатом взятия производной от преобразования в первой подсети и имеется влияние значений линейной активации $A^{k,l}$ первой подсети на вычисление нелинейного преобразования в одноимённых (с совпадающими индексами) элементах (см. формулы (27) и (28)) во второй и третьей подсетях

Для обучения в конечном итоге нас интересуют значения частных производных ошибки E по всем параметрам (весам связей) $w_{k,j,l}$, $\frac{\partial E}{\partial w_{k,j,l}}$, которые определяют направления и величину изменения $w_{k,j,l}$ в процессе обучения сети. Для вычисления частных производных (для связей выходного слоя) применим ступенчатую формулу:

$$\frac{\partial E}{\partial w_{k,j,l}} = \frac{\partial E}{\partial Net} \frac{\partial Net}{\partial w_{k,j,l}} + \frac{\partial E}{\partial Net_x} \frac{\partial Net_x}{\partial w_{k,j,l}} + \frac{\partial E}{\partial Net_t} \frac{\partial Net_t}{\partial w_{k,j,l}}, \quad (17)$$

это связано с тем, что, согласно (15) и (16)

$$E = \frac{1}{2} F(u, u_x, u_t)^2 = \frac{1}{2} F(Net, Net_x, Net_t)^2. \quad (18)$$

Введём обозначения «ошибки» $\delta^{k,l}$ (коэффициента линейной пропорциональности изменения ошибки при дифференциально малом изменении

активности произвольного элемента сети: $\partial E = \delta^{k,l} \partial A^{k,l}$, для каждого элемента свой индивидуальный $\delta^{k,l}$ для каждого значения x и t). Для выходных активностей:

$$\delta^{M+1,1} \equiv \delta = \frac{\partial E}{\partial \text{Net}}; \delta_x^{M+1,1} \equiv \delta_x = \frac{\partial E}{\partial \text{Net}_x}; \delta_t^{M+1,1} \equiv \delta_t = \frac{\partial E}{\partial \text{Net}_t}. \quad (20)$$

Параметры δ , δ_x и δ_t определяют, в каком направлении следует изменять выходные значения нейросети Net , Net_x и Net_t при каждом значении x и t . И, что более важно, Net , Net_x и Net_t соответствуют (согласно (5) и (8)) входной активации выходных элементов $A^{M+1,1}$, $A_x^{M+1,1}$ и $A_t^{M+1,1}$. Для настройки весов связей $w_{k,j,l}$ всех элементов скрытых слоёв нужно научиться распространять расчёт «ошибок» $\delta^{k,l}$, $\delta_x^{k,l}$ и $\delta_t^{k,l}$ в обратном (к распространению активности) направлении по нейросети не только для активностей ($\delta^{k,l}$), но и для их производных по x и t ($\delta_x^{k,l}$ и $\delta_t^{k,l}$).

Естественно начать с вычисления δ , δ_x и δ_t (20), значения которых определяются только видом функции (18) (и (5)) и величинами x и t .

$$\delta = \frac{\partial E}{\partial \text{Net}} = F(\text{Net}, \text{Net}_x, \text{Net}_t)(1 + tu'_0 + t^2 \cdot \text{Net}_x), \quad (21)$$

$$\delta_x = \frac{\partial E}{\partial \text{Net}_x} = F(\text{Net}, \text{Net}_x, \text{Net}_t)(tu'_0 + t^2 \cdot \text{Net}), \quad (22)$$

$$\delta_t = \frac{\partial E}{\partial \text{Net}_t} = F(\text{Net}, \text{Net}_x, \text{Net}_t)(t). \quad (23)$$

Для вычисления весов связей, приходящих на выходные элементы сети (Net , Net_x и Net_t), осталось только вычислить производные $\frac{\partial \text{Net}}{\partial w_{M+1,j,1}}$, $\frac{\partial \text{Net}_x}{\partial w_{M+1,j,1}}$ и $\frac{\partial \text{Net}_t}{\partial w_{M+1,j,1}}$, поскольку связи выходного слоя имеют следующие номера: $k = M + 1$, $j = 1 \dots N_M$, $l = 1$. Исходя из (3) и (6)

$$\frac{\partial \text{Net}}{\partial w_{M+1,j,1}} = \frac{\partial O^{M+1,1}}{\partial w_{M+1,j,1}} = \frac{\partial A^{M+1,1}}{\partial w_{M+1,j,1}} = O^{M,j}, \quad (24)$$

$$\frac{\partial \text{Net}_v}{\partial w_{M+1,j,1}} = \frac{\partial O_v^{M+1,1}}{\partial w_{M+1,j,1}} = \frac{\partial A_v^{M+1,1}}{\partial w_{M+1,j,1}} = O_v^{M,j}, \quad (25)$$

где v – это x и t . Формулы (21) – (25) позволяют, используя (17), вычислять значения $\frac{\partial E}{\partial w_{M+1,j,1}}$ и приращения весов связей выходного слоя:

$$\Delta w_{M+1,j,1} = -\alpha \frac{\partial E}{\partial w_{M+1,j,1}}; \quad 0 < \alpha \ll 1. \quad (26)$$

Но, естественно, для хорошей аппроксимации функции (в данном случае – решения уравнения Хопфа) необходимо использовать многослойную сеть со значительным числом скрытых слоёв и настраивать связи всех скрытых элементов. Для этого необходимо распространить «ошибки» $\delta^{k,l}$, $\delta_x^{k,l}$ и $\delta_t^{k,l}$ по всей сети на основе значений «ошибок» δ , δ_x и δ_t .

Некоторое отличие от традиционного (без производных) «обратного распространения ошибок» состоит в том, что при нелинейном преобразовании в нейроподобных элементах скрытых слоёв при вычислении производных Net_x и Net_t результат зависит не от одного параметра (как в случае $A^{k,l}$ и Net (8), (10), а от двух параметров ($A^{k,l}$ и $A_v^{k,l}$ (12)), то есть для вычисления Net_x и Net_t используются нелинейные преобразования не одной, а двух переменных, которое обозначим $\varphi(A^{k,l}, A_v^{k,l})$:

$$O_v^{k,l} = \sigma(A^{k,l})_v = \sigma'(A^{k,l})A_v^{k,l} = \varphi(A^{k,l}, A_v^{k,l}). \quad (27)$$

Соответственно, полный дифференциал $O_v^{k,l}$ будет зависеть от приращений обеих переменных:

$$dO_v^{k,l} = \frac{\partial O_v^{k,l}}{\partial A^{k,l}} dA^{k,l} + \frac{\partial O_v^{k,l}}{\partial A_v^{k,l}} dA_v^{k,l} = \sigma''(A^{k,l})A_v^{k,l} dA^{k,l} + \sigma'(A^{k,l})dA_v^{k,l}. \quad (28)$$

При распространении «ошибок» на последний скрытый слой (номер слоя $k = M$) «лесенка» частных производных продолжится и расширится:

$$\begin{aligned} \frac{\partial E}{\partial w_{M,j,l}} &= \left(\frac{\partial E}{\partial Net} \frac{\partial Net}{\partial O^{M,l}} \frac{\partial O^{M,l}}{\partial A^{M,l}} + \frac{\partial E}{\partial Net_x} \frac{\partial Net_x}{\partial O_x^{M,l}} \frac{\partial O_x^{M,l}}{\partial A^{M,l}} + \right. \\ &\frac{\partial E}{\partial Net_t} \frac{\partial Net_t}{\partial O_t^{M,l}} \frac{\partial O_t^{M,l}}{\partial A^{M,l}} \left. \right) \frac{\partial A^{M,l}}{\partial w_{M,j,l}} + \frac{\partial E}{\partial Net_x} \frac{\partial Net_x}{\partial O_x^{M,l}} \frac{\partial O_x^{M,l}}{\partial A_x^{M,l}} \frac{\partial A_x^{M,l}}{\partial w_{M,j,l}} + \\ &\frac{\partial E}{\partial Net_t} \frac{\partial Net_t}{\partial O_t^{M,l}} \frac{\partial O_t^{M,l}}{\partial A_t^{M,l}} \frac{\partial A_t^{M,l}}{\partial w_{M,j,l}} = \frac{\partial E}{\partial A^{M,l}} \frac{\partial A^{M,l}}{\partial w_{M,j,l}} + \frac{\partial E}{\partial A_x^{M,l}} \frac{\partial A_x^{M,l}}{\partial w_{M,j,l}} + \frac{\partial E}{\partial A_t^{M,l}} \frac{\partial A_t^{M,l}}{\partial w_{M,j,l}} = \\ &\delta^{M,l} O^{M-1,j} + \delta_x^{M,l} O_x^{M-1,j} + \delta_t^{M,l} O_t^{M-1,j}. \end{aligned} \quad (29)$$

Сумма в скобках обязана своим появлением тому, что от $A^{k,l}$ зависит не только $O^{k,l}$, но и $O_x^{k,l}$ и $O_t^{k,l}$. Производные по весам связей равны выходной активности элементов предыдущего слоя (согласно (3) и (6)). Формула (29) кажется очень громоздкой (и в такой форме записи – является), но использование обозначений «ошибок» $\delta^{M,l}$, $\delta_x^{M,l}$ и $\delta_t^{M,l}$ позволяет её заметно упростить. Сами же $\delta^{M,l}$, $\delta_x^{M,l}$ и $\delta_t^{M,l}$ могут быть рассчитаны на основе «ошибок» δ , δ_x и δ_t :

$$\begin{aligned} \delta^{M,l} &= \frac{\partial E}{\partial Net} \frac{\partial Net}{\partial O^{M,l}} \frac{\partial O^{M,l}}{\partial A^{M,l}} + \frac{\partial E}{\partial Net_x} \frac{\partial Net_x}{\partial O_x^{M,l}} \frac{\partial O_x^{M,l}}{\partial A^{M,l}} + \frac{\partial E}{\partial Net_t} \frac{\partial Net_t}{\partial O_t^{M,l}} \frac{\partial O_t^{M,l}}{\partial A^{M,l}} = \\ &= w_{M+1,l,1} (\delta \sigma'(A^{M,l}) + \delta_x \sigma''(A^{M,l}) A_x^{M,l} + \delta_t \sigma''(A^{M,l}) A_t^{M,l}), \end{aligned} \quad (30)$$

$$\delta_x^{M,l} = \frac{\partial E}{\partial A_x^{M,l}} = \frac{\partial E}{\partial Net_x} \frac{\partial Net_x}{\partial O_x^{M,l}} \frac{\partial O_x^{M,l}}{\partial A_x^{M,l}} = \delta_x w_{M+1,l,1} \sigma'(A^{M,l}), \quad (31)$$

$$\delta_t^{M,l} = \frac{\partial E}{\partial A_t^{M,l}} = \frac{\partial E}{\partial Net_t} \frac{\partial Net_t}{\partial O_t^{M,l}} \frac{\partial O_t^{M,l}}{\partial A_t^{M,l}} = \delta_t w_{M+1,l,1} \sigma'(A^{M,l}). \quad (32)$$

Возможность (в (30)) выноса $w_{M+1,l,1}$ за скобки обусловлена тем, что хотя величины Net , Net_x и Net_t вычисляются разными сетями, но все три сети имеют одинаковую структуру (и значения величин весов) связей, а

отличаются только нелинейными преобразованиями в элементах скрытых слоёв.

И, наконец, можно считать $\delta^{k,j}$, $\delta_x^{k,j}$ и $\delta_t^{k,j}$ по всей сети для произвольных элементов j любых скрытых слоёв k через $\delta^{k+1,l}$, $\delta_x^{k+1,l}$ и $\delta_t^{k+1,l}$

$$\begin{aligned} \delta^{k,j} &= \frac{\partial E}{\partial A^{k,j}} = \left(\sum_l \frac{\partial E}{\partial A^{k+1,l}} \frac{\partial A^{k+1,l}}{\partial O^{k,j}} \right) \frac{\partial O^{k,j}}{\partial A^{k,j}} + \\ &+ \left(\sum_l \frac{\partial E}{\partial A_x^{k+1,l}} \frac{\partial A_x^{k+1,l}}{\partial O_x^{k,j}} \right) \frac{\partial O_x^{k,j}}{\partial A^{k,j}} + \left(\sum_l \frac{\partial E}{\partial A_t^{k+1,l}} \frac{\partial A_t^{k+1,l}}{\partial O_t^{k,j}} \right) \frac{\partial O_t^{k,j}}{\partial A^{k,j}} = \\ &= (\sum_l \delta^{k+1,l} w_{k+1,j,l}) \sigma'(A^{k,l}) + (\sum_l \delta_x^{k+1,l} w_{k+1,j,l}) \sigma''(A^{k,l}) A_x^{k,l} + \\ &+ (\sum_l \delta_t^{k+1,l} w_{k+1,j,l}) \sigma''(A^{k,l}) A_t^{k,l}. \end{aligned} \quad (33)$$

$$\delta_x^{k,j} = \frac{\partial E}{\partial A_x^{k,j}} = \left(\sum_l \frac{\partial E}{\partial A_x^{k+1,l}} \frac{\partial A_x^{k+1,l}}{\partial O_x^{k,j}} \right) \frac{\partial O_x^{k,j}}{\partial A_x^{k,l}} (\sum_l \delta_x^{k+1,l} w_{k+1,j,l}) \sigma'(A^{k,l}). \quad (34)$$

$$\delta_t^{k,j} = \frac{\partial E}{\partial A_t^{k,j}} = (\sum_l \frac{\partial E}{\partial A_t^{k+1,l}} \frac{\partial A_t^{k+1,l}}{\partial O_t^{k,j}}) \frac{\partial O_t^{k,j}}{\partial A_t^{k,l}} = (\sum_l \delta_t^{k+1,l} w_{k+1,j,l}) \sigma'(A^{k,l}). \quad (35)$$

После расчёта всех $\delta^{k,l}$, $\delta_x^{k,l}$ и $\delta_t^{k,l}$, можно рассчитать все $\frac{\partial E}{\partial w_{k,j,l}}$ и $\Delta w_{k,j,l}$:

$$\frac{\partial E}{\partial w_{k,j,l}} = \delta^{k,l} O^{k-1,j} + \delta_x^{k,l} O_x^{k-1,j} + \delta_t^{k,l} O_t^{k-1,j}, \quad (36)$$

$$\Delta w_{k,j,l} = -\alpha \frac{\partial E}{\partial w_{k,j,l}}; \quad 0 < \alpha \ll 1. \quad (37)$$

Обучение глубоких нейросетей, конечно, не сводится только к использованию градиентного спуска, есть ещё ряд методов, улучшающих сходимость обучения. Но данная работа посвящена только методу обратного распространения ошибки в случае вычисления аппроксимации не только значений функции, но и её производных, когда функция задана не явно, а дифференциальным уравнением.

Выводы

Поставленная задача была решена, но при машинном моделировании следует использовать не только полученные результаты, но весь доступный арсенал средств, повышающих сходимость преобразования, осуществляемого нейросетью, к требуемому виду.

Была проведена серия тестов по вычислению функции, удовлетворяющей уравнению Хопфа с заданным начальным условием (функция $u_0(0, x)$) с помощью нейросетей по описанной методике. Расчёты проводились на прямоугольной области 0–0.5 по t и 0–1 по x . Известно, что при монотонно неубывающих начальных функциях точные решения получаются гладкими, иначе могут быть разрывы. С другой стороны, известно, что нейронная сеть всегда даёт гладкие решения, поэтому ясно, что в случае негладкого точного решения найденное решение вблизи разрыва будет неточным. Хочется надеяться, что эта неточность будет только в малой области вблизи разрыва.

Для монотонно неубывающих начальных функций найденные решения довольно точно совпадают с известными точными решениями. Для разрывных точных решений найденное решение качественно соответствует точным, однако неточность в области разрыва иногда оказывается шире, чем хотелось бы. В плане дальнейших работ стоит улучшение аппроксимации для разрывных решений.

Список литературы

1. Ashby W.R. Introduction to Cybernetics. London: Chapman & Hall Ltd. 1956.
2. Krizhevsky A., Sutskever I., Hinton G.E. ImageNet classification with deep convolutional neural networks // Communications of the ACM. 2017. V. 60, N 6. P. 84–90.
3. Silver D., Hubert T., Hassabis D. [et al.]. Mastering Chess and Shogi by Self-Play with a General Reinforcement Learning Algorithm // arXiv:1712.01815. 2017.
4. Mikolov T., Sutskever I., Chen K., Corrado G., Dean J. Distributed representations of words and phrases and their compositionality // Advances in Neural Information Processing Systems // arXiv:1310.4546. 2013.
5. Babenko A., Lempitsky V. Aggregating local deep features for image retrieval // Proceedings of the IEEE international conference on computer vision. 2015. P. 1269–1277.
6. Rumelhart D.E., Hinton G.E., Williams R.J., Learning Internal Representations by Error Propagation // Parallel Distributed Processing: Explorations in the Microstructure of Cognition: Foundations. MIT Press. 1986. V. 1. P. 318–362.
7. Гудфеллоу Я., Бенджио И., Курвилль А. Глубокое обучение. Москва : ДМК Пресс. 2018.
8. Николенко С., Кадурин А., Архангельская Е. Глубокое обучение. Погружение в мир нейронных сетей. СПб. : Питер. 2018. 480с.
9. Bengio Y., LeCun Y., Hinton G. Deep Learning for AI // Communications of the ACM. 2021. V. 64, N 7. P. 58–65.
10. Hopf E. The partial differential equation $u_t + u u_x = \mu x x$ // Communications on Pure and Applied Mathematics. 1950. V. 3. P. 201–230.

Н.В. ЧАПЛИНСКАЯ

Институт проблем управления им. В.А. Трапезникова РАН, Москва,
Московский государственный технический университет им. Н.Э. Баумана
nadya1462@gmail.com

**ОБУЧЕНИЕ СПАЙКОВОЙ НЕЙРОННОЙ СЕТИ НА
ОСНОВЕ ИЗМЕНЕНИЯ ВРЕМЕННЫХ ЗАДЕРЖЕК НА
СИНАПСАХ**

В статье описывается новое правило обучения спайковой нейронной сети, основанное на биологическом эффекте пластичности временных задержек на синапсах. С помощью данного правила спайковая нейронная сеть из трех нейронов была успешно обучена распознавать три контрастных образа.

Ключевые слова: *спайковые нейронные сети, синаптическая пластичность, синаптические задержки, кодирование временем первого спайка, распознавание образов.*

Введение

Спайковые нейронные сети часто называют третьим поколением искусственных нейронных сетей. Ключевое различие между традиционной искусственной нейронной сетью и спайковой – это способ распространения информации. В то время как классическая искусственная нейронная сеть работает с вещественными или целочисленными входами и выходами, спайковая нейронная сеть оперирует данными, представленными в виде серии импульсов (спайков), пытаясь наиболее близко воспроизвести поведение реальной биологической нейронной сети. В наше время спайковые нейронные сети (СНС) успешно решают широкий класс задач и применяются в таких областях, как протезирование [1], робототехника [2], компьютерное зрение [3] и другие. Существуют примеры таких обученных систем, конвертирующих данные непосредственно с датчиков [4], управляющих манипуляторами [5] и роботами [6], решающих задачи распознавания или задачи обнаружения [7], задачи тактильного восприятия [8] и обработки нейромедицинских данных [9]. Наряду с прочими заслугами спайковые нейронные сети открыли целое направление создания различных нейроморфных систем (Neurogrid [10], BrainScaleS [11]) и нейроморфных чипов (Loihi [12], Tianjic [13]), успешная работа которых свидетельствует о большом потенциале аппаратной реализации СНС.

Пластичность синаптических весов [14] и пластичность синаптических задержек [15] – это существующие в биологической нейронной сети явления, сопровождающие процесс ее обучения. Однако если обучение изменением весов синапсов – метод, широко применяемый во многих научных работах ([16], [17]), то эффект пластичности временной задержки на синапсе практически не исследован применительно к обучению.

Исключение составляют две современные работы: в первой [18] спайковая нейронная сеть обучается как пластичностью весов, так и пластичностью задержек, а во второй [19] выбор делается в пользу обучения исключительно пластичностью задержек. Тем не менее в обеих работах используются большие СНС, что не дает возможности в деталях проследить функционирование каждого нейрона.

В рассматриваемой работе предлагается новое правило обучения на основе пластичности задержек, работа которого была продемонстрирована с использованием максимально простой сети: для распознавания трех контрастных образов оказалось достаточным взять три нейрона модели leaky-integrate-and-fire (LIF). Также, ввиду работы с временными задержками, в качестве кодирования изображений было выбрано временное кодирование – кодирование временем первого спайка, что к тому же существенно ускорило процесс обучения.

Постановка задачи

Синаптическая пластичность – один из ключевых механизмов, обеспечивающих обучение биологических нейронных сетей. Синаптическая пластичность означает способность синапса – места соединения двух нейронов – изменять свои характеристики под влиянием внешних факторов, таких как, например, активность пресинаптического и постсинаптического нейрона. Исследуемая в данной работе характеристика – временная задержка спайка на синапсе.

Цель работы – описать и обосновать работоспособность нового предлагаемого правила обучения, основанного на синхронизации поступающих в пост-нейрон спайков путем изменения временных задержек на синапсах.

В качестве обоснования работоспособности правила в работе приводятся результаты обучения смоделированной спайковой нейронной сети, использующей введенное правило обучения. При этом, ввиду акцентов работы на описании и понимании внутрисетевых процессов, в данном исследовании были исключены любые другие возможные усложнения системы: выбрана однослойная сеть с минимальным числом нейронов,

которая обладает простым строением нейронов и простой архитектурой.

Обучение и тестирование проводятся для задачи распознавания образов. Для моделирования работы описанной спайковой нейронной сети используется симулятор Brian2.

Концепция обучения спайковой нейронной сети

В данной работе процесс обучения спайковой нейронной сети предлагается проводить следующим образом. Паттерн экспонируется несколько раз, в каждый из которых выходные нейроны, подстраивая задержки на синапсах от входных нейронов, соревнуются в том, кто первым сможет среагировать на этот паттерн. Необходимый эффект конкуренции нейронов за паттерн обеспечивается наличием латеральных связей с тормозящими синапсами (рис. 1). Первый среагировавший выходной нейрон, считая себя победителем, подавляет возможности остальных выходных нейронов далее подстраивать свои задержки под данный паттерн, при этом задержки на синапсах к самому нейрону-победителю продолжают подстраиваться. С целью предотвратить переобучение победившего нейрона другими паттернами при каждой его активации параметр скорости обучения (*Learning Rate*) уменьшается. Таким образом, на следующем паттерне данный выигравший нейрон будет уже менее восприимчив к обучению и бороться за новый паттерн будут, главным образом, другие выходные нейроны.

В модели используется временное кодирование, паттерны кодируются временем первого спайка (TTFS): например, если говорить об изображениях, то входной нейрон от самого яркого пикселя выдаст спайк первым, а входной нейрон от самого темного пикселя выдаст спайк последним на текущей экспозиции изображения (рис. 1).




Рис. 1. Предлагаемая архитектура сети с кодированием паттерна временем первого спайка (TTFS)

Описание и демонстрация предлагаемого обучающего правила

В процессе обучения задержки на синапсах должны меняться так, чтобы выходной нейрон начал реагировать на данный паттерн. Этого можно добиться, если обучающее правило обеспечивает синхронизацию приходящих на выходной нейрон спайков, что в модели нейрона leaky-integrate-and-fire приводит к резкому увеличению мембранного потенциала, который при правильно подобранных параметрах преодолевает порог активации – нейрон генерирует собственный спайк.

Предлагаемое в данной работе обучающее правило состоит в следующем: времена спайков, приходящих на выходной нейрон от входных нейронов с учетом синаптической задержки, постепенно должны приближаться к определенному синхронизационному моменту времени. С точки зрения реализации правила, это можно описать следующим образом:

On PRE (on presynaptic spike):

$$\Delta delay = Learning\ Rate \cdot (tpre_{target} - tpre_{current})$$

$$delay = delay + \Delta delay$$

On POST (on postsynaptic spike):

$$Learning\ Rate = 0.8 \cdot Learning\ Rate$$

Здесь $tpre_{target}$ – целевой момент синхронизации приходящих спайков, а $tpre_{current}$ – время пришедшего на выходной нейрон спайка с учетом текущей задержки на синапсе.

Для демонстрации работы правила рассмотрим простейшую сеть из двух входных нейронов, генерирующих спайки в моменты времени, соответствующие некоторому паттерну, и одного выходного нейрона, принимающего эти спайки. При любом начальном распределении задержек на синапсах выходного нейрона правило должно обучить сеть так, чтобы финальные задержки способствовали практически синхронному прибытию входящих спайков и, как следствие, реакции выходного нейрона на данный паттерн. Выберем целевой момент синхронизации спайков равным времени возникновения первого спайка, сдвинутого на t_{max} вправо по временной оси, где t_{max} должно быть не меньше, чем разница между временем самого позднего и самого раннего пришедшего спайка.

Пусть паттерн задан таким образом, что первый спайк в экспозиции генерируется первым входным нейроном, причем задержку на соответствующем синапсе выберем по значению меньше t_{max} , то есть в процессе обучения она должна расти.

Начальное значение задержки на синапсе от второго входного нейрона выберем так, чтобы значение $tpre_{current}$ было больше, чем целевой момент

синхронизации $tpre_{target}$. В этом случае задержка будет уменьшаться до тех пор, пока момент времени $tpre_{current}$ не окажется близок к целевому значению $tpre_{target}$.

Процесс изменения задержек на синапсах от первого и второго входного нейрона можно наблюдать на графике (рис. 2). Изменение мембранного потенциала выходного нейрона (рис. 3) демонстрирует постепенное сближение реакций на входные спайки (причем реакция на первый спайк приближается к целевому значению слева, а на второй спайк справа), что в конечном итоге на шестой экспозиции паттерна приводит к активации выходного нейрона.




Рис. 2. Демонстрация правила: задержка на синапсе от первого входного нейрона увеличивается, от второго входного нейрона – уменьшается. Вертикальный пунктир – момент входного спайка, вертикальный жирный пунктир – момент выходного спайка




Рис. 3. Демонстрация правила: изменение мембранного потенциала выходного нейрона. Вертикальный пунктир – целевой момент синхронизации

Описание результатов обучения сети из трех нейронов

В качестве демонстрации корректной работы предложенного правила обучения была решена задача распознавания трех простейших образов спайковой нейронной сетью из десяти входных нейронов и трех выходных нейронов с латеральными тормозящими связями, создающими конкуренцию.

Образы представляют собой световые линейки из десяти пикселей, на каждой из которых световое пятно смещено в определенном направлении: центр, правая сторона и левая сторона (рис. 4).




Рис. 4. Три изображения из 10 пикселей: верхнее – световое пятно в центре, среднее – световое пятно справа, нижнее – световое пятно слева

Чтобы определились нейроны-победители для всех трех образов, оказалось достаточным экспонировать каждый образ пять раз. Вначале экспонировалось «левое» изображение, затем «правое» и затем «центральное».

На рисунке 5 можно проследить процесс изменения задержек на синапсах всех трех выходных нейронов от первого и последнего (десятого) входного нейрона. Начальные задержки были заданы произвольным образом. Видно, что первый выходной нейрон на первой же экспозиции побеждает и подстраивает свои синаптические задержки под «левое» изображение, подавляя попытки остальных нейронов подстроить собственные задержки. В итоге финальная задержка на синапсе первого выходного нейрона от первого входного нейрона (со стороны самого яркого левого пикселя) максимальна, а от последнего входного нейрона (со стороны самого темного правого пикселя) минимальна, что приводит к синхронизации спайков на данных синапсах при экспозиции «левого» изображения.




Рис. 5. Изменение задержек на синапсах каждого из трех выходных нейронов: верхний ряд – от первого входного нейрона, нижний ряд – от последнего входного нейрона

Аналогичным образом дело обстоит с третьим выходным нейроном, который побеждает на второй экспозиции «правого» изображения и, в конечном итоге, имеет зеркальные задержки на синапсах (от минимальной к максимальной).

Второй выходной нейрон побеждает на четвертой экспозиции «центрального» изображения и имеет минимальные финальные задержки на синапсах от первого и последнего нейрона, но максимальные от центральных нейронов. Сравнить начальные и финальные задержки на синапсах трех выходных нейронов можно, посмотрев на рис. 6.




Рис. 6. Распределение задержек на синапсах: до обучения – верхний график, после обучения – нижний график

На тестировании тридцатью слабо зашумленными вариантами данных изображений обученная нейронная сеть показала стопроцентный результат точности распознавания.

В качестве дополнительного исследования был проведен эксперимент по снижению контрастности изображений с сохранением средней яркости пикселей. Изменение точности распознавания, как результат данного эксперимента, можно наблюдать на рис. 7.




Рис. 7. Изменение F1-меры в течение проведения эксперимента по снижению контрастности

Выводы

В данной работе было предложено новое правило обучения спайковой нейронной сети, основанное на эффекте пластичности синаптических задержек, с использованием временного кодирования – кодирования временем первого спайка. Правило было продемонстрировано на взаимодействии двух входных и одном выходном (главном) нейроне.

На основе данного правила обучения была решена задача распознавания трех простейших контрастных образов из десяти пикселей спайковой нейронной сетью с тремя нейронами модели leaky-integrate-and-fire.

Данный результат может оказаться значимым с точки зрения определения роли синаптических задержек в алгоритмах децентрализованного обучения без учителя. В дальнейших работах планируется исследовать возможности предложенного правила на сетях другой архитектуры для решения более сложных задач. Также планируется вводить модификации предложенного правила в виде добавления иных характеристик синаптической пластичности с целью повышения уровня биологической правдоподобности исследуемых моделей.

Список литературы

1. Mosbacher Y. [et al.]. Toward neuroprosthetic real-time communication from in silico to biological neuronal network via patterned optogenetic stimulation // Scientific reports. 2020. V. 10, N 1. P. 1–16.
2. Furber S. B. [et al.]. The spinnaker project // Proceedings of the IEEE. 2014. V. 102. No. 5. P. 652–665.
3. Hopkins M. [et al.]. Spiking neural networks for computer vision // Interface Focus. 2018. V. 8. No. 4. P. 20180007.
4. Lovelace J.J., Rickard J.T., Cios K.J. A spiking neural network alternative for the analog to digital converter // The 2010 International Joint Conference on Neural Networks (IJCNN). IEEE, 2010. P. 1–8.
5. Bouganis A., Shanahan M. Training a spiking neural network to control a 4-dof robotic arm based on spike timing-dependent plasticity // The 2010 International Joint Conference on Neural Networks (IJCNN). IEEE, 2010. P. 1–8.
6. Alnajjar F., Murase K. Sensor-fusion in spiking neural network that generates autonomous behavior in real mobile robot // 2008 IEEE International Joint Conference on Neural Networks (IEEE World Congress on Computational Intelligence). IEEE, 2008. P. 2200–2206.
7. Pérez-Carrasco J.A. [et al.]. Fast vision through frameless event-based sensing and convolutional processing: Application to texture recognition // IEEE transactions on neural networks. 2010. V. 21, N 4. P. 609–620.
8. Ratnasingham S., McGinnity T.M. A spiking neural network for tactile form-based object recognition // The 2011 International Joint Conference on Neural Networks. IEEE, 2011. P. 880–885.
9. Fang H., Wang Y., He J. Spiking neural networks for cortical neuronal spike train decoding // Neural Computation. 2010. V. 22, N 4. P. 1060–1085.
10. Benjamin B.V. [et al.]. Neurogrid: A Mixed-Analog-Digital Multichip System for Large-Scale Neural Simulations // Proceedings of the IEEE. 2014. V. 102, N 5. P. 699–716.
11. Schemmel J. [et al.]. Live demonstration: A scaled-down version of the BrainScaleS wafer-scale neuromorphic system // 2012 IEEE International Symposium on Circuits and Systems (ISCAS). 2012. P. 702–702.
12. Davies M. et al. Loihi: A Neuromorphic Manycore Processor with On-Chip Learning // IEEE Micro. 2018. V. 38, N 1. P. 82–99.
13. Pei, J., Deng, L., Song, S. [et al.]. Towards artificial general intelligence with hybrid Tianjic chip architecture // Nature. V. 572. No. 7767. P. 106–111.
14. Byrne J. Learning and memory: a comprehensive reference. Academic Press. 2017.
15. Lin J.W., Faber D.S. Modulation of synaptic delay during synaptic plasticity // Trends in neurosciences. 2002. T. 25. No. 9. P. 449–455.
16. Kheradpisheh S.R. [et al.]. STDP-based spiking deep convolutional neural networks for object recognition // Neural Networks. 2018. V. 99. P. 56–67.
17. Indiveri G. [et al.]. STDP and STDP variations with memristors for spiking neuromorphic learning systems // Frontiers in Neuroscience. 2013. V.7.

18. Nadafian A., Ganjtabesh M. Bio-plausible Unsupervised Delay Learning for Extracting Temporal Features in Spiking Neural Networks // arXiv preprint arXiv:2011.09380. 2020.
19. Hazan H. [et al.]. Memory via Temporal Delays in weightless Spiking Neural Network // arXiv preprint arXiv:2202.07132. 2022.

А.Ю. ШАМИН, Я.М. КАРАНДАШЕВ

Федеральный научный центр Научно-исследовательский институт системных исследований Российской академии наук, Москва
shamin_ay@mail.ru

НЕЙРОСЕТЕВОЙ МЕТОД РЕШЕНИЯ ДИФФЕРЕНЦИАЛЬНЫХ УРАВНЕНИЙ С РАЗЛИЧНЫМИ НАЧАЛЬНЫМИ ЗНАЧЕНИЯМИ*

Предлагается обобщение нейросетевого метода численного решения дифференциальных уравнений как обыкновенных, так и в частных производных с заданными начальными и граничными условиями. При этом предлагается обучать сеть вместе с начальными условиями. Таким образом, сеть обучается решать не только одну задачу с фиксированными начальными условиями, а целый класс с условиями в некотором диапазоне. Также в работе рассматривается несколько архитектур таких сетей с несколькими вариантами обучения.

Ключевые слова: *нейронная сеть, дифференциальные уравнения.*

Введение

Многие физические, химические и механические процессы моделируются посредством систем дифференциальных уравнений (ДУ). В задачах теоретической механики и управления используют обыкновенные ДУ, в задачах гидро- и аэродинамики – уравнения в частных производных. Поэтому, безусловно, изучение решений ДУ является до сих пор актуальной и важной задачей для науки и техники. Аналитическое исследование таких моделей зачастую связано с известными трудностями. В связи с этим развиты методы численного интегрирования таких систем (методы Рунге – Кутты, Розенброка, МКЭ, разностные методы и пр.). Они повсеместно используются в широкой практике, их тщательно изучают и совершенствуют. В настоящее время развиваются методы моделирования физических процессов, основанные на нейронных сетях с разнообразными подходами. В работах [1, 2] было предложено обучать сеть для решения дифференциальных уравнений, но с использованием дополнительных

* Настоящая работа выполнена в рамках государственного задания по проведению фундаментальных научных исследований по теме "Исследование нейроморфных систем обработки больших данных и технологии их изготовления" № FNEF-2022-0003.

численных методов. В работе [3] для моделирования механических процессов предлагается использовать уже графовые нейросети. В работах [4–6] предлагаются принципы нейросетевого моделирования, основанного на обучении сети с использованием дифференцирования выхода сети по ее входам. В настоящей работе развивается подход, предложенный в [7, 8], основанный на аппроксимации решения конкретной задачи Коши. В данной работе сравнивается несколько архитектур сети, а также в отличие от указанных работ предлагается обучать сеть вместе с начальными условиями. Это позволит решать задачу не только для уравнений с фиксированными начальными значениями, но с произвольными из некоторого диапазона. При этом в качестве функции невязки предлагается использовать сумму двух функций ошибок. Первая функция – это сумма значений левой части самого дифференциального уравнения $F(x^{(n)}(t), \dots, \dot{x}(t), x(t), t) = 0$ в конечном числе точек области. Вторая – отклонение сети от начального условия. Простота применения такого подхода обусловлена тем, что взятие необходимых производных происходит посредством автоматического дифференцирования [9] и вычисляется точно, а аппроксимация решения происходит в процессе обучения сети.

Постановка задачи

Рассматривается следующая задача. Имеется задача Коши:

$$\begin{cases} F(x^{(n)}(t), \dots, \dot{x}(t), x(t), t) = 0, & t \in (a, b), \\ x^i(a) = q_i, & i = 0 \dots n-1. \end{cases} \quad (1)$$

Требуется найти $x = x(t)$, удовлетворяющее условиям (1). Эта задача также переписывается в следующем виде:

$$\begin{cases} \dot{x}(t) = x_1(t), \\ \dot{x}_1(t) = x_2(t), \\ \dots \\ \dot{x}_{n-2}(t) = x_{n-1}(t) & t \in (a, b), \\ F(\dot{x}_{n-1}(t), x_{n-1}(t), \dots, x_1(t), x(t)) = 0, \\ x_i(a) = q_i, & i = 0 \dots n-1, \end{cases} \quad (2)$$

где требуется найти набор $x(t), x_1(t), \dots, x_{n-1}(t)$, удовлетворяющий системе (2).

Предлагается строить аппроксимацию решения в виде нейросети:

$$\tilde{f}(t, q_0, q_1, \dots, q_{n-1}) \rightarrow \mathbb{R}, \quad (3)$$

на вход которой подается число t из интервала (a, b) , а выход пытается предсказать значение решения задачи (1) или (2) в точке, поданной на вход. При этом можно рассматривать фиксированные значения q_i , в таком случае на вход сети подается только t .

Сравнение архитектур

Описание сетей

Предлагается для сравнения три типа архитектуры сети для решения следующей задачи:

$$\begin{cases} \dot{x}(t) = y(t), \\ \dot{y}(t) = F(x(t), y(t), t) \quad t \in (a, b), \\ x(a) = x_0, \quad y(a) = y_0. \end{cases} \quad (4)$$

Сеть 1, по сути, состоит из двух подсетей, на вход каждой подается момент $t \in (a, b)$, выход первой предсказывает $x(t) = \tilde{f}_x(t)$, а выход второй подсети $y(t) = \tilde{f}_y(t)$. Каждая из сетей $\tilde{f}_x, \tilde{f}_y$ из 6 слоев: входной и выходной, состоящие из одного нейрона, а также трех скрытых полносвязных слоя по 40 нейронов в каждом. На втором слое функция активации – синус, на третьем – экспонента, на 4 и 5 слоях – функция *softmax*. Функция ошибки состоит из двух слагаемых:

$$\begin{aligned} Loss &= Loss_1 + Loss_2, \\ Loss_1 &= \left(\dot{\tilde{f}}_x(t) - \tilde{f}_y(t) \right)^2 + \left(\dot{\tilde{f}}_y(t) - F(\tilde{f}_x(t), \tilde{f}_y(t), t) \right)^2, \\ Loss_2 &= \left(\tilde{f}_x(a) - x_0 \right)^2 + \left(\tilde{f}_y(a) - y_0 \right)^2. \end{aligned} \quad (5)$$

Первое слагаемое отвечает за отклонение предсказания подсетей от своего уравнения, а второе – за отклонение от начальных условий.

Сеть 2 представляет собой одну подсеть из первой сети с тем исключением, что выходной слой состоит из двух нейронов, первый предсказывает $x(t) = \tilde{f}_x(t)$, а второй $y(t) = \tilde{f}_y(t)$. Таким образом, эта сеть имеет меньше параметров, но выходы связаны между собой теснее. Функция ошибки имеет такой же, как и (5).

Для сети 3 изменим постановку задачи с (4) на

$$\begin{cases} G(\ddot{x}(t), \dot{x}(t), x(t), t) = 0, \quad t \in (a, b), \\ x(a) = x_0, \quad \dot{x}(a) = y_0. \end{cases} \quad (6)$$

Здесь $G(\ddot{x}(t), \dot{x}(t), x(t), t) = \ddot{x} - F(x(t), \dot{x}(t), t)$.

Сеть 3 представляет собой ровно одну подсеть сети 1, причем выходной слой также состоит из одного нейрона, предсказывающего $x(t) = \tilde{f}(t)$ по моменту t , попадающему на входной нейрон. Для сети 3 функция ошибки будет следующей:

$$\begin{aligned} Loss &= Loss_1 + Loss_2, \\ Loss_1 &= \left(G(\ddot{f}(t), \dot{\tilde{f}}(t), \tilde{f}(t), t) \right)^2, \\ Loss_2 &= \left(\tilde{f}(a) - x_0 \right)^2 + \left(\dot{\tilde{f}}(a) - y_0 \right)^2. \end{aligned} \quad (7)$$




Рис. 1. Архитектура сетей

Стоит отметить, что производные выходов нейросетей $\dot{\tilde{f}}_x(t), \dot{\tilde{f}}_y(t)$, а также $\ddot{f}(t), \dot{\tilde{f}}(t), \dot{\tilde{f}}(a)$ вычисляются в Pytorch посредством автоматического дифференцирования в модуле Autograd.

Обучение

Обучение каждой из трех сетей происходило двумя способами. В обоих случаях сеть обучалась в течение $M = 1000$ эпох. В первом случае на каждой эпохе на вход подавался набор $\{t_i\}_{i=1}^N, t_i \sim U(a, b)$. Во втором случае эпохе с номером j подавался набор $\{t_i\}_{i=1}^N, t_i \sim U\left(a, a + (b - a) \frac{j}{M}\right)$. $N = 1000$ в обоих случаях. Таким образом, во втором случае в начале обучения сеть

училась на точках, ближе расположенных к начальным условиям, и с ростом номера эпохи отрезок равномерного распределения увеличивается. В первом случае сеть сразу учится на точках всего отрезка.

Сравнение

Для сравнения работы трех сетей в двух режимах обучения попробуем решить несколько модельных задач. Первая задача о линейном осцилляторе заключается в решении системы (4) для случая

$$F(x(t), y(t), t) = -x(t), x_0 = 2, y_0 = 0,$$

что в случае (6) эквивалентно

$$G(\ddot{x}(t), \dot{x}(t), x(t), t) = \ddot{x}(t) + x(t), x_0 = 2, y_0 = 0.$$

Решение будем искать на отрезке $t \in [0; 32\pi]$. Результаты приведены на рисунке 2. Нумерация сетей следующая: первое число соответствует номеру сети, второе – типу обучения. Видно, что лучший результат дает сеть 3, причем выбор 2 метода обучения с изменяющимся интервалом распределения дает результат лучше по сравнению с обучением на всем отрезке. Вероятно, это связано с тем, что сеть лучше аппроксимирует начальные условия, в результате чего приближение на всем отрезке получается лучше.




Рис. 2. Решения $x(t)$ для задачи о линейном осцилляторе

Вторая модельная задача – затухающий осциллятор, а именно:

$$F(\dot{x}(t), y(t), t) = -10x(t) - y(t), x_0 = 2, y_0 = 0,$$

что в случае (6) эквивалентно

$$G(\ddot{x}(t), \dot{x}(t), x(t), t) = \ddot{x}(t) + \dot{x}(t) + 10x(t), x_0 = 2, y_0 = 0.$$

Решение будем искать на отрезке $t \in [0; 2\pi]$. Результаты представлены на рисунках 3-4.




Рис. 3. Решения $x(t)$ для задачи о затухающем осцилляторе




Рис. 4. Фазовые портреты для задачи о затухающем осцилляторе

Можно заметить, что лучшие результаты дает снова сеть 3 при обучении на разных отрезках. Можно предположить, что среди предложенных архитектур лучше оказывается та, которая основана на аппроксимации всего уравнения.

Обучение на разных начальных условиях

Предлагается обучить сеть на решение параметрического класса задач Коши. Схематичное изображение архитектуры представлено на рисунке 5. На вход сети подается не только t , но и параметры, которые задают конкретную задачу Коши.




Рис. 5. Архитектура сети для параметрической задачи

В качестве иллюстрации метода решим следующую задачу:

$$\begin{cases} \ddot{x}(t) + 2\alpha_1 \dot{x}(t) + \alpha_2 x(t), & x \in [0; 4\pi], \\ x(0) = \beta, \quad \dot{x}(0) = \gamma, \\ \alpha_1 \in [1, 3], \quad \alpha_2 \in [-10; 10], \\ \beta, \gamma \in [-5; 5]. \end{cases} \quad (8)$$

На каждой эпохе обучения на вход сети подается $t_i \sim U\left(0, 4\pi \frac{j}{M}\right)$, а также $\beta, \gamma \sim U(-5, 5)$, $\alpha_1 \sim U(1, 3)$, $\alpha_2 \sim U(-10; 10)$. Решение задачи при некоторых значениях параметров представлено на рис. 6. Точность решения составляет порядка $10^{-2} - 10^{-3}$ в абсолютной величине. Таким образом, имеется возможность обучать сеть не на конкретную задачу Коши, а на параметрический класс.




Рис. 6. Решение при разных значениях параметра

Заключение

Предложено развитие метода численного интегрирования дифференциальных уравнений, основанного на аппроксимации решения нейросетью. Выделены для сравнения несколько возможных архитектур и показано, что при использовании функции ошибки для уравнения дает лучший результат по сравнению с аналогичными сетями, которые отдельно предсказывают все компоненты эквивалентной системы. Также показано, что в некоторых случаях возможно улучшить качество оценки сети, обучая ее, постепенно увеличивая диапазон подаваемых на вход значений t .

Метод обобщен на случай параметрического семейства задач Коши так, чтобы сеть могла обучаться решать задачу с различными начальными условиями и коэффициентами, задающими само дифференциальное уравнение.

Список литературы

1. Chen R., Rubanova Yu., Bettencourt J., Duvenaud D. Neural Ordinary Differential Equations // arXiv:1806.07366. 2019.
2. Holl P., Koltun V., Thuerey N. Learning to Control PDEs with Differentiable Physics // arXiv:2001.07457. 2020.
3. Pfaff T., Fortunato M., Sanchez-Gonzalez A., Battaglia P. Learning Mesh-Based Simulation with Graph Networks // arXiv:2010.03409. 2021.
4. Васильев А.Н., Тархов Д.А. Принципы и техника нейросетевого моделирования. СПб. : Нестор-История. 2014. 217 с.
5. Tarkhov D., Vasilyev A. Semi-empirical Neural Network Modeling and Digital Twins Development. Academic Press, Elsevier. 2019.
6. Брусов В.С., Тюменцев Ю.В. Нейросетевое моделирование движения летательных аппаратов. Москва : Изд-во МАИ. 2016. 192 с.
7. Maziar R., Paris P., George K. Physics Informed Deep Learning (Part I): Data-driven Solutions of Nonlinear Partial Differential Equations // arXiv:1711.10561. 2017.
8. Maziar R. Deep Hidden Physics Models: Deep Learning of Nonlinear Partial Differential Equations // arXiv:1801.06637. 2018.
9. Baydin A., Barak P., Radul A., Jeffrey S. Automatic differentiation in machine learning: A survey // Journal of Machine Learning Research. 2019. V. 18. P. 1–43.

ПРИКЛАДНЫЕ НЕЙРОСЕТЕВЫЕ СИСТЕМЫ

**Р.О. БАРИНОВ, В.Е. ГАЙ, И.В. ПОЛЯКОВ, Г.Д. КУЗНЕЦОВ,
А.А. ТИЩЕНКО**

Нижегородский государственный технический университет им. Р.Е. Алексеева
barinovr@list.ru

МОДЕЛЬ И АЛГОРИТМЫ АВТОМАТИЧЕСКОЙ ОЦЕНКИ РЕЗУЛЬТАТОВ ОБУЧЕНИЯ НЕЙРОННОЙ СЕТИ

Рассматривается задача автоматической оценки результатов обучения нейронной сети на основе анализа кривых обучения. Анализ кривых обучения сводится к извлечению предложенного признакового описания и последующей классификации с помощью модели классического машинного обучения. Предлагаемая модель автоматической оценки служит для повышения степени автоматизации и интерпретации процесса обучения нейронной сети.

Ключевые слова: *кривые обучения, классификация, автоматизация оценки обучения.*

Введение

Процесс обучения искусственной нейронной сети – это итеративный процесс, который заключается в поиске параметров сети, при которых обученная сеть достигает оптимальных параметров качества работы.

В процессе обучения алгоритм оптимизации стремится свести к минимуму функцию ошибки сети, однако процесс обучения не всегда идет гладко. Специалисты в области глубокого обучения пытаются как можно раньше обнаружить проблемы, возникающие в процессе обучения. К таким проблемам относятся проблемы обучения сети. Пропуск и игнорирование проблем, возникающих в процессе обучения, может привести к снижению качества работы сети или сделать сеть совершенно непригодной к использованию для решения прикладных задач, что, в свою очередь, влечет за собой необходимость повторного обучения, а значит, дополнительных временных и финансовых затрат.

Настоящая работа направлена на решение проблемы автоматической оценки результатов процесса обучения нейронной сети путём создания модели и алгоритмов для автоматической классификации состояния процесса обучения нейронной сети. В свою очередь классификация состояния

процесса обучения позволит повысить степень интерпретации данного процесса.

Обзор методов обнаружения проблем обучения моделей

1. Экспертный метод. Для детектирования ошибок обучения нейронных сетей эксперты в области глубокого обучения применяют ряд правил [1–3], основанных на понимании математического процесса обучения.

Экспертный метод оценки результатов обучения предполагает непосредственный контроль за процессом обучения сети со стороны специалиста. В свою очередь на специалиста в области глубокого обучения подобная задача по своевременному и качественному выявлению ошибок в процессе обучения накладывает дополнительную ответственность и риски. Экспертный метод напрямую зависит от компетенций и опыта лица, принимающего решения, а также влечет за собой увеличение времени разработки моделей нейронных сетей.

2. Обратные вызовы API Keras. Keras – это API для глубокого обучения [4]. Обратный вызов API Keras – это функция, которая может выполняться на различных этапах обучения модели нейронной сети. Подобные функции применяются, в частности, для управления параметром скорости обучения, изменение которого может повлиять на поведение алгоритма обучения.

Главным недостатком описанного метода является тот факт, что большинство параметров, с помощью которых происходит обнаружение событий некорректного поведения модели в процессе её обучения, являются константами, заданными заранее специалистами, или набором правил, который также заранее формируется человеком до начала обучения модели. Стоит отметить то, что сами события, которые возможно обнаружить данным методом никак не классифицируются. Заранее предполагается, что конкретный сконфигурированный обратный вызов API Keras обнаружит событие, которое только предположительно (конечное решение принимается специалистом, следящим за ходом обучения) и лишь на данном этапе обучения модели, является событием переобучения или отсутствия обучения модели. К недостаткам метода также можно отнести отсутствие готовых автоматических инструментов обнаружения предполагаемого недообучения модели.

3. Ранняя остановка обучения за счет экстраполяции кривых обучения. В работе [5] предлагается подход к ускорению поиска оптимальных гиперпараметров модели нейронной сети за счет ранней остановки обучения. Критерием для такой остановки служат экстраполированные кривые обучения.

Метод ранней остановки обучения за счет экстраполяции кривых обучения дает возможность оценить значение функции точности y_m на шаге m , однако решение о том, что данная модель подвержена переобучению или количество эпох обучения m будет недостаточным (то есть сохраняется состояние недообучения), должен принимать какой-либо внешний по отношению к рассматриваемому методу механизм или эксперт. Следовательно, при таком подходе автоматизация процесса оценки обучения является частичной, требующей привлечения дополнительных методов.

Модель автоматической оценки результатов обучения сети

В настоящей работе предлагается модель автоматической оценки результатов обучения нейронной сети (рис. 1) на основе метрик качества, получаемых в ходе обучения модели нейронной сети.



Рис. 1. Модель автоматической оценки результатов обучения нейронной сети

На каждом шаге обучения модели нейронной сети оптимизатор рассчитывает заданные метрики качества работоспособности сети. Если рассматривать решение задачи классификации, то основными метриками являются функция ошибки, например бинарная или кросс-энтропия, и доля верных ответов. Исходя из этого, целесообразно рассматривать данные метрики как временные ряды с шагом, равным одной эпохе обучения модели.

Полученные от оптимизатора метрики качества обучения используются для вычисления ряда признаков, которые в свою очередь подаются на

вход системе классификации. Система классификации определяет состояние процесса обучения на данной эпохе. Было выделено три состояния: нормальное, недообучение и переобучение.

Результат классификации, то есть оценка состояния обучения на текущей эпохе, передается интеллектуальной системе управления процессом обучения, которая в совокупности с исходными метриками качества обучения принимает решение о корректировке процесса обучения, его остановки или продолжения без изменений.

Таким образом, задача автоматической оценки результатов обучения нейронной сети сводится к задаче многоклассовой классификации на три класса.

Сбор и формирование выборки данных

Основными критериями для отбора информации являлись виды метрик качества обучения нейронных сетей. Отбирались исключительно кривые обучения функций ошибок и точности, которые зависят от пройденных эпох обучения.

После выполнения этапа сбора данных полученные графики кривых обучения переводились из графического представления во временные ряды.

Стоит отметить, что из-за того, что данные собирались из многочисленных источников, невозможно было собрать одну целостную выборку данных. В связи с этим было сформировано две выборки. Одна из них включает в себя данные кривых обучения функций ошибок, а другая — данные кривых обучения функции точности.

Признаковое описание кривых обучения

Признаковое описание кривых обучения целесообразно разделить на два вида: признаки, вычисляемые по кривым обучения и функций ошибок и кривым обучения функции точности; признаки, вычисляемые только по кривым обучения функции точности.

Такое разделение вызвано тем фактом, что ряд предлагаемых признаков имеет смысл вычислять исключительно на нормированных данных. Нормированными в данном случае являются временные ряды, полученные по кривым обучения функции точности, значения которой лежат в диапазоне $[0, 1]$. В свою очередь значения временных рядов, полученные по кривым функций ошибок, не являются нормированными.

Предлагается ввести следующие общие признаки для всех рассматриваемых кривых обучения вне зависимости от вида функции (ошибки или точности).

1. Стандартное отклонение разности функций рассматриваемой мет-

рики на обучении и валидации:

$$f_1 = \sigma(F_{t_i} - F_{v_i}), i = \overline{1, N}, \quad (1)$$

где F_t – функция метрики на обучении, F_v – функция метрики на валидации, N – количество эпох обучения модели нейронной сети.

2. Стандартное отклонение функции рассматриваемой метрики на обучении:

$$f_2 = \sigma(F_{t_i}), i = \overline{1, N}. \quad (2)$$

3. Стандартное отклонение функции рассматриваемой метрики на валидации:

$$f_3 = \sigma(F_{v_i}), i = \overline{1, N}. \quad (3)$$

4. Среднее значение производной функции рассматриваемой метрики на крайних эпохах обучения:

$$f_4 = \frac{1}{N(1-k)} \sum_{i=N(1-k)}^N F'_{t_i}, \quad (4)$$

где k – процент крайних эпох обучения, на которых вычисляется данный признак. Эмпирически параметр k был установлен равным 10%.

5. Среднее значение производной функции рассматриваемой метрики на крайних эпохах валидации:

$$f_5 = \frac{1}{N(1-k)} \sum_{i=N(1-k)}^N F'_{v_i}. \quad (5)$$

6. Стандартное отклонение функции рассматриваемой метрики на крайних эпохах обучения:

$$f_6 = \sigma(F_{t_i}), i = \overline{N(1-n), N}, \quad (6)$$

где n – процент крайних эпох обучения, на которых вычисляется данный признак. Эмпирически параметр n был установлен равным 20%.

7. Стандартное отклонение функции рассматриваемой метрики на крайних эпохах валидации:

$$f_7 = \sigma(F_{v_i}), i = \overline{N(1-n), N}. \quad (7)$$

8. Ряд дискретных базисных функций из теории активного восприятия [6], вычисляемых для обеих метрик на обучении и валидации:

$$f_8 = -F_{t_i} - F_{t_{i+\frac{1}{4}N}} + F_{t_{i+\frac{1}{2}N}} + F_{t_{i+\frac{3}{4}N}}, i=1, \frac{1}{4}N, \quad (8)$$

$$f_9 = -F_{t_i} + F_{t_{i+\frac{1}{4}N}} + F_{t_{i+\frac{1}{2}N}} - F_{t_{i+\frac{3}{4}N}}, i=1, \frac{1}{4}N, \quad (9)$$

$$f_{10} = F_{t_i} - F_{t_{i+\frac{1}{4}N}} + F_{t_{i+\frac{1}{2}N}} - F_{t_{i+\frac{3}{4}N}}, i=1, \frac{1}{4}N, \quad (10)$$

$$f_{11} = -F_{v_i} - F_{v_{i+\frac{1}{4}N}} + F_{v_{i+\frac{1}{2}N}} + F_{v_{i+\frac{3}{4}N}}, i=1, \frac{1}{4}N, \quad (11)$$

$$f_{12} = -F_{v_i} + F_{v_{i+\frac{1}{4}N}} + F_{v_{i+\frac{1}{2}N}} - F_{v_{i+\frac{3}{4}N}}, i=1, \frac{1}{4}N, \quad (12)$$

$$f_{13} = F_{v_i} - F_{v_{i+\frac{1}{4}N}} + F_{v_{i+\frac{1}{2}N}} - F_{v_{i+\frac{3}{4}N}}, i=1, \frac{1}{4}N. \quad (13)$$

Предлагается ввести следующие признаки для кривых обучения функции точности.

1. Разность между конечным и начальным значениями функции точности на обучении:

$$f_{14} = F_{t_N} - F_{t_1}. \quad (14)$$

2. Разница между конечным и начальным значениями функции точности на валидации:

$$f_{15} = F_{v_N} - F_{v_1}. \quad (15)$$

3. Разность между конечными значениями функции точности на обучении и валидации:

$$f_{16} = F_{t_N} - F_{v_N}. \quad (16)$$

4. Площадь под кривыми обучения функции точности на обучении/валидации.

6. Максимальное значение функции точности на обучении:

$$f_{17} = \max(F_t). \quad (17)$$

7. Максимальное значение функции точности на валидации:

$$f_{18} = \max(F_v). \quad (18)$$

8. Разность между конечным и начальным значениями функции точности на крайних эпохах обучения:

$$f_{19} = F_{t_N} - F_{t_{N(1-n)}}. \quad (19)$$

Эмпирически параметр n был установлен равным 20%.

9. Разность между конечным и начальным значениями функции точности на крайних эпохах валидации:

$$f_{20} = F_{v_N} - F_{v_{N(1-n)}}. \quad (20)$$

Таким образом, признаковое описание кривых обучения состоит из 13 признаков для функций потерь и из 22 признаков для функции точности.

Классификация состояния процесса обучения модели

Исходя из сформированных выборок данных и их признаковых описаний, было принято решение о создании алгоритма классификации на основе двух независимых классификаторов (рис. 2).



Рис. 2. Алгоритм классификации состояния процесса обучения

На вход алгоритма классификации подаются признаковые описания кривых обучения функций ошибки и точности, полученные в процессе извлечения признаков.

Далее два классификатора определяют вероятности принадлежности признаков описаний кривых обучения к каждому из трех классов: нормальному, недообучению, переобучению.

На следующем этапе происходит вычисление максимального значения из полученных коэффициентов и принятие решения о классе состояния процесса обучения. Таким образом, алгоритм классификации состоит из трех основных этапов:

1. Непосредственная классификация входных признаков описаний кривых обучения двумя независимыми классификаторами.
2. Объединение результатов классификации.
3. Принятие решения о классе состояния процесса обучения.

Выбор моделей классификаторов

В данном эксперименте по выбору моделей классификаторов, после процесса извлечения признаков и применения алгоритма аугментации данных SMOTE, обучающие выборки получили следующие распределения: выборка данных кривых обучения функций ошибок – 387 объектов, выборка данных кривых обучения функции точности – 225 объектов.

Эксперимент заключался в проведении кросс-валидации.

Таблица 1

Метрики качества работы классификаторов

Выборки данных	Кривые обучения функций ошибок			Кривые обучения функции точности		
	accuracy	precision	recall	accuracy	precision	recall
Decision Tree	0,734	0,733	0,734	0,791	0,795	0,791
SVC (OvO)	0,336	0,554	0,336	0,640	0,701	0,640
SVC (OvO, Polynomial Features)	0,337	0,328	0,337	0,724	0,719	0,724
SVC (OvA)	0,354	0,392	0,408	0,782	0,806	0,796
SVC (OvA, Polynomial Features)	0,440	0,417	0,411	0,810	0,824	0,822
K-Neighbors	0,612	0,615	0,612	0,769	0,770	0,769
Logistic Regression	0,292	0,293	0,292	0,649	0,701	0,646
Gradient Boosting	0,780	0,789	0,788	0,879	0,872	0,872
Random Forest	0,860	0,862	0,860	0,880	0,876	0,876

Из представленных результатов видно, что наиболее эффективными с точки зрения рассмотренных метрик качества моделями классификаторов для определения класса состояния процесса обучения по признаковому описанию кривых обучения функций ошибки и функции точности являются модели классификаторов случайный лес.

Сравнение предлагаемой модели с аналогом

Для проведения вычислительного эксперимента по сравнению предлагаемой модели с аналогами было принято решение создать и обучить 20 моделей искусственных нейронных сетей для решения задачи классификации.

Критерием, по которому производилось сравнение моделей между собой, является среднее значение разностей номеров эпох обучения, на которых была произведена остановка процессе обучения. В случае с предлагаемой моделью, эпохой, на которой производится остановка обучения, будет считаться эпоха, на которой результатом работы алгоритма классификации состояния процесса обучения является класс «переобучение».

$$Q = \frac{1}{N} \sum_{i=1}^N n_m^{(i)} - n_a^{(i)}, \quad (21)$$

где N – количество моделей нейронных сетей, n_m – номер эпохи остановки обучения в случае с предлагаемой моделью автоматической оценки результатов обучения нейронной сети, n_a – номер эпохи остановки обучения в случае модели аналога.

Для каждой модели нейронной сети было задано строго фиксированное число эпох обучения равное 100. Для сравнения работоспособности разработанной модели использовался метод «Early stopping» API Keras, ручная конфигурация которого не производилась.

По результатам эксперимента было получено следующее значение параметра Q для обратных вызовов API Keras: – 0,15.

Отрицательное и близкое к нулю значение параметра Q говорит о том, что в большинстве случаев разработанная модель определяет наступление состояния переобучения одновременно с методом «Early stopping» API Keras, иногда опережая его на 3–5 эпох.

Однако стоит заметить, что метод обратных вызовов API Keras не предоставляет информацию, позволяющую интерпретировать результат обучения, в отличие от предлагаемой модели.

Выводы

В рамках данного исследования был выполнен обзор методов обнаружения проблем обучения нейронных сетей. Был сделан ряд выводов о существующих недостатках рассмотренных методов. Авторами предложена модель автоматической оценки результатов обучения нейронной сети.

Такой подход позволяет не только автоматизировать процесс выявления проблем обучения, но и предоставляет инструментарий, позволяющий обучать модели глубокого обучения неспециалистам в области машинного обучения без необходимости в дополнительных консультациях по интерпретации результатов.

Вычислительный эксперимент показал, что метрики качества работы системы классификации состояния процесса обучения оказались сопоставимы с метриками аналога.

В перспективе развития модели планируется выполнить следующие этапы:

- 1) разработка интеллектуальной системы управления процессом обучения, позволяющей изменять конфигурацию оптимизатора в процессе обучения, а также влиять на сам процесс обучения модели нейронной сети;
- 2) расширение множества моделей, для оценки процесса обучения которых предназначена предлагаемая модель.

Список литературы

1. Koehrsen W. Overfitting vs. underfitting: A complete example // Towards Data Science. 2018.
2. Ying X. An overview of overfitting and its solutions // Journal of Physics: Conference Series. IOP Publishing. 2019. V. 1168, N 2. P. 022022.
3. Li H. [et al.]. Research on overfitting of deep learning //2019 15th International Conference on Computational Intelligence and Security (CIS). IEEE. 2019. P. 78-81.
4. Chollet F. Deep Learning with Python // Manning; 2nd edition. 2021. 504 p.
5. Domhan T., Springenberg J. T., Hutter F. Speeding up automatic hyper parameter optimization of deep neural networks by extrapolation of learning curves // Twenty-fourth international joint conference on artificial intelligence. 2015.
6. Утробин В.А. Элементы теории активного восприятия изображений // Труды Нижегородского государственного технического университета им. Р.Е. Алексеева. 2010. Т. 81, № 2. С. 61-69.

G.S. BRYKIN¹

¹ Bauman Moscow State Technical University, Moscow, Russia
glebbrykin@colorfulsoft.ru

DEOLDIFY.NET: CROSS-PLATFORM APPLICATION FOR COLORING BLACK AND WHITE PHOTOS

The problem of image coloring is an old problem that researchers have been solving for many years. Solutions based on neural networks have made it possible to improve the quality of the results to indistinguishable from the quality of real color images, or images colored by a professional in a graphic editor. Coloring old photos has become very popular with the release of various online services; in addition, there was a request for an application that can work offline. The article is devoted to a cross-platform desktop application for automatic coloring of black and white images, which is a port of the well-known DeOldify [1] development.

Keywords: *Machine Learning, Data Analysis, Image Colorization, .NET Framework [2], Mono [3], .NET Core [2], Managed Code.*

Introduction

Coloring of black-and-white images refers to forecasting tasks and is reduced to finding the most probable values of chromaticity based on the local and global semantics of the brightness channel of a black-and-white image. There are many approaches to solving this problem, both statistical and neural network. Statistical approaches, such as the Welch [4] color transfer algorithm, do not allow processing complex images with a large number of different objects, and also have a high error. Algorithms based on neural networks allow achieving high accuracy on various images and are the basis of modern services for restoring old images. This paper describes a desktop cross-platform application for coloring black and white images using the well-known DeOldify neural network. At the time of writing, this application had no analogues.

Related Work

This section covers only services and algorithms that have demo versions. There are many other research papers in this area, however, that does not have implementations for easy launch and do not give high enough quality.

Colorful image colorization & Demos.Algorithmia

One of the pioneering works in the field of neural coloring of black and white images belongs to Richard Sheng [5]. The article and code based on the Caff  framework were published in 2016, after some time a web service [6] using this development appeared. The service was available via the link <https://demos.algorithmia.com/colorize-photos>. The service was a free demonstration of the capabilities of the commercial API.

Let there be Color!: Automatic Colorization of Grayscale Images

This work [7] has significantly improved the accuracy of staining due to the application of a number of improvements described in detail in the article for the SIGGRAPH 2016 conference. The code is written in Lua and uses the Torch7 machine learning framework. For a simple launch of a neural network, the authors offered a free web service. The service was available via the link <http://hi.cs.waseda.ac.jp/~iizuka/projects/colorization/>, however, was already unavailable at the time of writing.

color.artlebedev

A free online service for coloring black and white images based on neural networks [8]. It is not working at the time of writing, it is available at the link <https://color.artlebedev.ru/gallery/>.

9may.mail.ru

This is online service for coloring black and white portraits from mail.ru [9]. It is available for free at the link: <https://9may.mail.ru/restoration/>.

DeOldify & MyHeritage

DeOldify [10] is the most modern and most accurate model for coloring black and white images at the time of writing. DeOldify combines many different approaches and tricks used previously in other tasks to improve the accuracy of color prediction. MyHeritage is an online service based on DeOldify. Registration is required to work, and then several free colorings are available. Then a paid subscription is required.

ImageColorizer

This is an application for restoring old photos for Windows [11]. There is a possibility of coloring black-and-white images; however, an Internet connection is required to use it, since the neural network runs on the developers' servers.

Demos

The essence of the project [12] is to implement popular neural algorithms for image coloring, image styling, and image super resolution in pure C#. Each algorithm in the proposed project is presented as an independent application with a convenient graphical interface for the Windows operating system. The goal of the project is to be able to quickly run neural algorithms on desktop computers. This is the previous stage of the System.AI project.

Proposed solution

The proposed solution is an autonomous cross-platform and lightweight application for Windows, Linux and macOS operating systems that implements the DeOldify neural network and a graphical interface to it. All components of the application are implemented from scratch in C# 5 programming language and are focused on the cross-platform capabilities of the .NET Framework platform or its implementations Mono, .NET, .NET Core. This solution allows to abstract from hardware and software to a large extent, which allows to run the same application on different versions of operating systems, as well as different processor architectures, while not requiring complex preparation and configuration, as happens with solutions in Python, C++ and Lua. The application does not require an Internet connection, image processing takes place on the user's device, which significantly increases the security and fault tolerance of the application. On Windows operating systems newer than Windows 7 .NET Framework is pre-installed, so to compile and run DeOldify.NET no additional software installation is required: there are enough tools built into the operating system. On the Windows 7 operating system, you need to install .NET Framework 4.5 or newer, which is not difficult. On Linux and macOS operating systems, you need to install Mono, however, there are detailed instructions for this. Preparing Linux and macOS for launch DeOldify.NET it takes several minutes even for an unprepared user.

Methods

The key role in the success and applicability of the machine learning framework, as well as any other software product, is the efficiency of the code. The implementation of neural network components in managed code is of particular interest, since it requires the use of rare specific features of the language

and platform. Let's consider the approach used to implement DeOldify.NET components on the example of the matrix multiplication algorithm.

Optimize the algorithm taking into account the architecture of the computing system: avoid inconsistent access to memory.

Implement multithreading.

Use direct access to array elements via pointers to avoid checks.

Take advantage of the possibilities of pointer arithmetic.

Implement vectorization.

Consistent execution of the optimizations mentioned above allows getting a performance gain of more than 33 times compared to the classical algorithm. Measurements were carried out in 64-bit mode for 1000x1000 matrices.

Table 1

The impact of different approaches to code optimization on its execution time

Heading level	Time, ms	Efficiency
Naïve	3867	517.2 MFlops
+ Cache	2633	759.6 MFlops
+ Multithreading	903	2.2 GFlops
+ Pointers	531	3.8 GFlops
+ Arithmetic	261	7.6 GFlops
+ SIMD	117	17 GFlops

There are several ways to further improve performance, one of which is using .NET 5 or .NET Core, which will make it more efficient to use vector processor instructions than it does on .NET 4.8 with System.Numerics.Vector4. When developing DeOldify.NET uses compromise solutions that allows get maximum efficiency in memory and time. New algorithms and approaches are often being developed. For example, in convolution layers, a modified im2col algorithm is used: instead of extracting all the necessary patches of the input image into the matrix, followed by multiplying this matrix by the matrix of convolution ker-

nels, as it usually happens, in DeOldify.NET each individual patch of the image is converted into a vector, which is immediately multiplied by a matrix of weights. This solution allows you to radically reduce the additional memory for calculating convolution, and also shows a performance level comparable to the classic `im2col`. The use of such tricks is possible due to the fact that the DeOldify.NET does not rely on ready-made mathematical libraries, as many similar products do, instead, all the necessary code is written from scratch. Another important aspect is the storage of neural network parameters on disk. DeOldify has a very large number of parameters and storing them in the traditional form will require more than 200 megabytes of disk space. To reduce the disk space occupied by the parameters, they are stored in the `float16` (half) data type, which allows you to reduce the file size by 2 times without significant loss of accuracy. The layout of the `float16` type value is shown in Fig. 1.




Fig. 1. `float16` layout

The graphical interface is implemented using Windows Forms technology. An important advantage of it is cross-platform (Mono is supported on Linux and macOS), easy use and stability. Interface appearance of DeOldify.NET on Linux Mint and Windows 7 operating systems are shown in Figures 1 and 2 respectively.




Fig. 2. DeOldify.NET main window on Linux Mint




Fig. 3. DeOldify.NET main window on Windows 7

Algorithms

An important condition for obtaining high software efficiency is good algorithms. When developing DeOldify.NET selects compromise solutions to achieve high performance in time and memory. Special attention is paid to the algorithms of convolutional layers. In particular, the new **patch2vec** algorithm was developed, which is a combination of the naive algorithm and the matrix `im2col`. The meaning of most fast convolution algorithms, such as `im2col` or `im2row`, involves bringing the convolution to matrix multiplication, which allows optimizing memory access operations by using the processor cache. However, such methods either require a buffer for $\text{srcC} * \text{kernelY} * \text{kernelH} * \text{dstH} * \text{dstW}$ elements, which is extremely irrational. The proposed `patch2vec` method unwraps each patch of the input image on the fly, and then applies all convolution filters to it. This implementation is not inferior in efficiency to classical algorithms like `im2col`, and in practice even surpasses them. The buffer for this algorithm will have the size of $\text{srcC} * \text{kernelY} * \text{kernelX}$, which is much smaller than in the case of similar methods. Moreover, `patch2vec` does not impose restrictions on the convolution parameters, unlike, for example, the Shmuel Vinograd method. The proposed algorithm is difficult to fit into classical machine learning frameworks due to the fact that they are focused on using GEMM as the core. Pure C#-based implementations make it easy to do this. As a result of the analysis of existing articles on the topic of fast convolutions [13] [14], it was found that the proposed algorithm is new and has not been presented before.

Future work

DeOldify.NET have collected quite a lot of positive reviews on github, and in many there is a request to add some useful features, such as batch image processing, a command-line interface, the use of a stable modification of the neural network from the original DeOldify repository. The primary task is the implementation of this functionality.




Fig. 4. An illustration of the patch2vec algorithm

Conclusion and Outlook

In the course of the work, all the tasks were completed. A new fast convolution algorithm was developed; various approaches to program code optimization were investigated and applied. The presented software solution for coloring black-and-white photos using AI in offline mode has no analogues in a number of characteristics. Source codes, binaries and docs related to this project are available on GitHub under Apache-2.0 license: <https://github.com/ColorfulSoft/DeOldify.NET>

References

1. DeOldify repository, <https://github.com/jantic/DeOldify>, last accessed 2022/08/25.
2. DotNet Homepage, <https://dotnet.microsoft.com/>, last accessed 2022/08/25.
3. Mono Homepage, <https://www.mono-project.com/>, last accessed 2022/08/25.
4. Welsh T., Ashikhmin M., Mueller K. Transferring Color to Greyscale Images // ACM Transactions on Graphics. 2002. V. 21, N 3. P. 277–280/
5. Zhang R., Isola P., Alexei A. Efros A.A. Colorful Image Colorization // Computer Vision ECCV 2016. ECCV 2016. Lecture Notes in Computer Science. Springer, Cham V. P. 649–666.

6. Algorithmia Image Colorization // <https://demos.algorithmia.com/colorize-photos>, last accessed 2020/01/26.
7. Iizuka S., Simo-Serra E., Ishikawa H. Let there be Color!: Joint End-to-end Learning of Global and Local Image Priors for Automatic Image Colorization with Simultaneous Classification, <http://hi.cs.waseda.ac.jp/~iizuka/projects/colorization/>, Special Interest Group on Computer Graphics and Interactive Techniques 2016.
8. Artlebedev Homepage: <https://color.artlebedev.ru/gallery/>, last accessed 2022/08/25.
9. 9may Homepage: <https://9may.mail.ru/restoration/>, last accessed 2022/08/25.
10. MyHeritage Image Colorization: <https://www.myheritage.com/incolor?lang=RU>, last accessed 2022/08/25.
11. ImageColorizer Homepage: <https://imagecolorizer.com/>, last accessed 2022/08/25.
12. Demos GitHub repository: <https://github.com/ColorfulSoft/StyleTransfer-Colorization-SuperResolution>, last accessed 2022/08/25.
13. Lavin, Scott Gray: Fast Algorithms for Convolutional Neural Networks // 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). 2016. P. 4013–4021. <https://arxiv.org/abs/1509.09308>
14. Trusov A.V., Limonova E.E., Nikolaev D.P., Arlazarov V.V.: p-im2col: Simple yet Efficient Convolution Algorithm with Flexibly Controlled Memory Overhead // IEEE Access. 2021. V. 9. P. 168162–168184.

Н.Т. ГАБДРАХМАНОВА¹, М.А. ПИЛЬГУН²

¹Российский университет дружбы народов, Москва

²Российский государственный социальный университет, Москва
gabdrakhmanova-nt@rudn.ru, pilgunm@yandex.ru

СВЁРТОЧНЫЕ НЕЙРОННЫЕ СЕТИ В ЗАДАЧАХ ОЦЕНКИ И ПРОГНОЗИРОВАНИЯ РАЗВИТИЯ СИТУАЦИИ ПО ЦИФРОВЫМ ДАННЫМ

Рассматривается задача динамического описания конфликтной ситуации в социуме в режиме реального времени на базе контента, генерированного пользователями, и их цифровых следов на примере реализации проекта Большой кольцевой линии метро (Южный участок). Интеграция нейросетевых и математических моделей позволила выявить семантические негативные акценты, определить позиционирование проекта в медиапространстве, сегменты наибольшего информационного внимания, социального напряжения вокруг строительства, а также спрогнозировать развитие ситуации.

Ключевые слова: *нейросетевые технологии, дифференциальные уравнения, прогнозирование.*

Введение

Исследование было направлено на анализ динамики информационной активности на цифровых ресурсах для отслеживания изменений настроения активной части населения города и отдельных районов Москвы, вовлеченных в обсуждение темы строительства Большой кольцевой линии метро (Южный участок) (БКЛ), определения ключевых тем контента, запускающих вовлеченность пользователей в обсуждение проекта и своевременного прогнозирования возникающих и/или развивающихся конфликтных ситуаций. Анализ проводился в период активной стадии строительства БКЛ (Южный участок), которая включала строительство трех новых станций БКЛ метро («Новаторская», «Воронцовская» и «Зюзино», а также реконструкцию станции «Каховская».

Для обеспечения эффективного управления необходимо знать, как развивается конфликт. Интеграция нейросетевых и математических моделей для анализа цифрового контента позволила выявлять реальные точки недовольства и позиционирование объекта в медиапространстве, сегменты наибольшего информационного внимания, социального напряжения

среди жителей Москвы и ее районов вокруг строительства БКЛ (Южный участок), а также спрогнозировать развитие ситуации.

Данные

Материалом для исследования послужили вербальный контент, генерированный пользователями на цифровых платформах, посвященный реализации проекта БКЛ (Южный участок), а также цифровые следы. Дата сбора данных: 1 Октября 2020 –10 Июня 2021 (табл. 1).

Таблица 1

Количественные характеристики данных

Количество токенов	62 657 289
Количество сообщений	7 063
Максимум сообщений в сутки	614
Количество активных авторов	933
Активность (постов на автора)	7,57
Количество источников	213

Для генерирования контента, посвященного реализации проекта БКЛ (Южный участок), акторы предпочитали использовать социальные сети, видеохостинги и микроблоги (рис. 1).




Рис. 1. Распределенность цифровых следов акторов по типам источников

Среди социальных сетей безусловным лидером являлась платформа ВКонтакте. Также популярными у пользователей были Инстаграм, Ютуб и Фейсбук (рис. 2).




Рис. 2. Распределенность цифровых следов акторов по типам источников

Метод

В работе представлена методика определения восприятия акторов определённой ситуации, которая проводится по результатам анализа контента, генерированного пользователями и их цифровых следов. В исследовании использован междисциплинарный подход. Для интерпретации данных применялись нейросетевой текстовый анализ, анализ лексических ассоциаций с помощью технологии TextAnalyst 2.3, подробное описание которых представлено в [1, 4]; контент-анализ [2, 3, 5] был выполнен с использованием сервиса AutoMap; sentiment-анализ проводился с помощью модуля определения тональности Eureka Engine.

Для эффективного анализа ситуации на основе цифровых данных осуществлена формализация задачи. Разработано достаточно много методов для анализа временных рядов [6]. Динамика ситуации анализируется с помощью построения математических моделей с использованием дифференциальных уравнений [7]. Сверточные нейронные сети (CNN) [8] и регрессионные модели [9] применены для прогнозирования временных рядов основных показателей.

Результаты

Общая характеристика контента

Динамика общего числа сообщений (рис.1*) показывает два пика роста: 24.03.2021 (2 241) 01.04.2021 (1 699). Аналогичную картину демон-

стрирует динамика числа уникальных сообщений 01.04.2021 (958) (рис. 2*).




Рис. 1*. Динамика общего числа сообщений




Рис. 2*. Динамика числа уникальных сообщений

Пик роста общего числа сообщений 24.03.2021 (2 241) определяется информацией о том, что москвичам предлагают проголосовать за название для новой станции БКЛ. Пик общего числа сообщений (1 699) и числа уникальных сообщений (958) приходится на 01.04.2021 и связан с открытием станции Большой кольцевой линии метро "Народное ополчение" и "Мневники".

Пик роста количества просмотров – 01.04.2021 (11 050 725) (рис. 3) и активности авторов – 24.03.2021 (1237); 01.04.2021 (599) (рис. 4) показывает аналогичные результаты.




Рис. 3. Динамика количества просмотров




Рис. 4. Динамика активности авторов

Геолокация цифровых следов акторов закономерно преобладание пользователей на территории России. Между тем зафиксированы акторы из разных стран, которые интересуются проблемами строительства БКЛ

(Южный участок). Анализ геолокации цифровых следов акторов по региону показывает, что максимальное число акторов представляют Центральный округ (ЦФЦ), также высокую активность проявляют акторы Нижегородской области и Северо-Западного округа (СЗО). Среди московских акторов наибольшую активность показывают акторы из Хорошево-Мневники, а также жители районов: Косино-Ухтомский, Марьино, Басманный район, Соколиная гора, Сокольники, Зюзино.

Тональность контента

Тональность подавляющего числа сообщений и цифровых следов в контексте упоминаний проекта нейтральная (рис. 5).




Рис. 5. Тональность контента по охвату




Рис. 6. Тональность цифровых следов пользователей

Сообщения с негативными и нейтральными постами генерировались на платформах (в порядке убывания): ВКонтакте, Телеграм, Твиттер, а позитивные сообщения размещались ВКонтакте, а также на mos.ru и Телеграм.

Анализ данных показал, что релевантный контент в 2021 году количественно значительно вырос по сравнению с 2020 годом (рис. 7). Конечно, нужно учитывать, что большинство контента генерируют ангажированные медиа. Между тем, важно отметить, что количество негативных сообщений выросло в 2,1, нейтральных – 2,2 раза, а позитивных – в 3,1.

Построение математической модели

Рассматриваемая задача относится к классу трудно формализуемых задач. На основе осуществленного выше анализа ситуации по цифровым данным принята следующая формализация задачи.

Введены следующие группы:

P – группа акторов с позитивным отношением к проекту, $p(t)$ – число комментариев группы P в момент t ,

N – группа акторов с негативным отношением к проекту, $n(t)$ – число комментариев группы N в момент t ;

U – группа акторов с нейтральным отношением к проекту, $u(t)$ – число комментов группы U в момент t .

В рамках рассматриваемой задачи, мы предположили, что процентное соотношение всех трех групп части социума, которая не вовлечена в социальные сети, такое же, как и у вовлеченной части. В силу того, что нас прежде всего интересует динамика числа акторов с позитивным и негативным отношением, и, учитывая, что активность постов колеблется в зависимости от дня недели, праздничных дней и т.д., принята следующая нормировка. Введены две новые переменные: $x(t) = p(t)/u(t)$ и $y(t) = n(t)/u(t)$. В табл. 2 приведен фрагмент исходных данных $x(t)$, $y(t)$. На рис. 7. динамика исходных данных $x(t)$ и $y(t)$.

Таблица 2

Фрагмент исходных данных

t	$x(t)$	$y(t)$
1	0,0537	0,0107
2	0,1024	0,0097
3	0,0357	0,0476
4	0,0217	0,1086
5	0,0645	0,0967
6	0,0845	0,0234

Общая постановка задачи

Даны временные ряды $\{x(t)\}$, $\{y(t)\}$, где $t = 1, \dots, N$, которые характеризуют уровень позитивного и негативного соответственно отношения к проекту. Шаг дискретизации постоянный. Необходимо по этим данным построить динамические модели для прогноза и анализа ситуации.




Рис. 7. Динамика исходных данных $x(t)$ и $y(t)$

Исследование тренда временных рядов

Тренды временных рядов $\{x(t)\}$, $\{y(t)\}$ построены методами регрессионного анализа. В результате оценок параметров модели получены следующие уравнения:

$$\begin{aligned}x(t) &= 0,1 + 0,001t, \\y(t) &= 0.06 + 0.0001t.\end{aligned}$$

Полученные оценки коэффициентов свидетельствуют о том, что ряд $\{x(t)\}$ растет быстрее, чем $\{y(t)\}$.

Математическая модель с помощью ОДУ

Для анализа поведения динамической системы важно иметь непрерывные математические модели. Наиболее подходящими непрерывными моделями являются дифференциальные уравнения. При выборе общего вида дифференциального уравнения рассматриваемую задачу можно представить как задачу соперничества – двухвидовой борьбы в популяциях, гонки вооружений, боевых действий. В данной работе мы представляем результаты построения математических моделей на основе ODE. Построенные модели исследуются на структурную устойчивость, наличие точек равновесия и точек бифуркаций. Мы рассмотрели различные виды

ODE. После сравнения результатов построения модели для описания процессов выбраны системы автономных дифференциальных уравнений. При аппроксимации коэффициентов моделей были использованы метод множественной регрессии и метод Нелдера – Мида. На первом шаге с помощью регрессионного анализа нашли оценки коэффициентов с помощью метода регрессионного анализа, затем это решение было скорректировано с помощью метода Нелдера – Мида. В результате реализации алгоритмов получено несколько вариантов моделей в виде систем дифференциальных уравнений. Одно из уравнений имеет следующий вид:

$$\begin{cases} \frac{dx}{dt} = 0.63x + 0.03y, \\ \frac{dy}{dt} = -0.1 + 0.5y. \end{cases}$$

Построенная модель исследовалась на структурную устойчивость. Собственные числа определителя системы $\lambda_1 = 0,6 + 0.13i$, $\lambda_2 = 0,6 - 0.13i$. Следовательно, точка покоя $(0, 0)$ – неустойчивый фокус. Это указывает на то, что при малом изменении векторного поля полученная система может оказаться не эквивалентной реальной. В силу этого для отслеживания динамики развития ситуации необходимо использовать параллельные модели, в частности модели прогноза временных рядов. Также можно отметить, что оценки коэффициентов системы дифференциальных уравнений свидетельствуют о том, что ряд $\{x(t)\}$ растет быстрее, чем $\{y(t)\}$.

В таблице 3 фрагмент результатов моделирования $x(t)$ на тестовом множестве. В таблице приняты следующие обозначения: t – время, x – реальное значение, $x^\wedge$ – модельное значение, e – абсолютная ошибка вычисления.

Таблица 3

Результаты моделирования (фрагмент)

t	x	$x^\wedge$	e
1	0,053763	0,051343	0,002421
2	0,102439	0,052691	0,049748
3	0,035714	0,054045	0,01833
4	0,021739	0,055404	0,03367
5	0,064516	0,056769	0,007748
6	0,084507	0,058137	0,02637

Математическая модель с помощью CNN

Традиционно разработанные для данных двумерного изображения CNN могут использоваться для моделирования одномерных и многомерных задач прогнозирования временных рядов. В нашей задаче данные рассматриваются в виде многомерного временного ряда. На вход CNN подавались данные с шагом 2. Выбор размера количества входных временных шагов имеет важное влияние на то, какой объём массива данных будет использоваться для тренировки. Оценка размера количества входных временных шагов получена с помощью оценок автокорреляций. При обучении нейронной сети на вход CNN подавался вектор $([x(k-2), y(k-2)], [x(k-1), y(k-1)])$, в качестве отклика взят вектор $[x(k), y(k)]$. Работа проводилась в среде Google Colaboratory (продукт Google Research, который используется для написания кода), модели были реализованы и обучены с помощью библиотек для машинного обучения, таких как: tensorflow, keras, sklearn. Дополнительно использовались математические библиотеки numpy, pandas и matplotlib для вычислений и создания графиков. При обучении CNN использован оптимизатор ADAMAX, в качестве функции активации использован ReLU. Получены следующие результаты обучения:

Epoch 98/100

164/164 - 0s - loss: 0.0140 - 405ms/epoch - 2ms/step

Epoch 99/100

164/164 - 0s - loss: 0.0141 - 404ms/epoch - 2ms/step

Epoch 100/100

164/164 - 0s - loss: 0.0139 - 396ms/epoch - 2ms/step

Train Score: 0.18 RMSE

Test Score: 0.30 RMSE

В таблице 4 фрагмент результатов моделирования.

Таблица 4

Фрагмент результатов моделирования

t	x	$x^{\wedge}$	e
10	0,179104	0,079104	0,1
11	0,290323	0,290323	3,33E-16
12	0,429688	0,36875	0,060938
13	0,233577	0,157664	0,075912
14	0,87218	0,5	0,37218
15	0,27897	0,1	0,17897

Обсуждение результатов

В статье исследованы методы построения математических моделей по цифровым данным; разработан алгоритм решения управленческой задачи. Основные шаги решения задачи: 1) с помощью нейронных сетей провести текстовый анализ контента и фильтрацию данных; 2) построить временные ряды по фильтрованным данным; 3) найти оценки параметров ОДУ моделей, провести анализ устойчивости моделей; 4) построить CNN для построения прогноза исследуемых переменных; 5) принятие управленческого решения на основе прогнозов ОДУ и CNN моделей.

С помощью построения прогноза временных рядов с использованием моделей ОДУ и CNN можно оценить уровень социального стресса и цифровой агрессии. Адекватность построенных моделей проверена с помощью построенного ретропрогноза (табл. 3 и табл.4).

Заключение

Основным, ключевым инструментом в выполненной работе являются нейросетевые модели. На первом этапе нейронные сети были использованы для текстового анализа и фильтрации данных. На следующем этапе на основе полученных решений осуществлена формализация и математическая постановка задачи. Показано, что анализировать и контролировать ситуацию можно на основе прогноза временных рядов с помощью CNN. В результате решения задачи сделаны конкретные выводы по данной ситуации. Они следующие.

Определение уровня социального стресса и цифровой агрессии в данном исследовании показало, насколько информационная активность и вовлеченность пользователей сети в обсуждение строительства БКЛ и производимые строительные работы на Южном участке остро воспринимаются жителями города Москвы и жителями районов строительства, а также позволила сделать выводы об уровне социального напряжения и одобрения текущей ситуации вокруг объекта исследования. Определённые потенциальные риски возникновения конфликта с жителями могут возникнуть при строительстве станции Воронцовская. Между тем, анализ данных и вычисления индексов социального стресса и благополучия позволили прогнозировать отсутствие открытого противодействия строительству со стороны жителей района. Развитие событий подтвердило корректность полученных результатов.

Список литературы

1. Kharlamov A., Pilgun M. (eds.) *Neuroinformatics and Semantic Representations. Theory and Applications*. Newcastle upon Tyne: Cambridge Scholars Publishing. 2020. 317 p.
2. Krippendorff K. *Content Analysis. An Introduction to Its Methodology*. Los Angeles: SAGE Publications, Inc. 2012. 441 p.
3. Mayring, P. Qualitative content analysis // *A companion to qualitative research*. 2004. N 1. P. 159-176.
4. Pilgun M., Raskhodchikov A.N., Koreneva Antonova O. Effects of COVID-19 on Multilingual Communication // *Frontiers in Psychology*. 2022. N 12.
5. White M.D., Marsh E. Content analysis: A flexible methodology // *Library Trends*. N 1. P. 22–45.
6. Gabdrakhmanova N., Fedin V., Matsuta B. The modeling of forecasting new situations in the dynamics of the economic system on the example of several financial indicators // 14th International Symposium «Intelligent Systems», INTELS'20, 14–16 December 2020, Moscow, Russia.
7. Арнольд В.И. *Геометрические методы в теории обыкновенных дифференциальных уравнений*. М.: МЦНМО. 2012. 384 с.
8. Шолле Ф. *Глубокое обучение на Python*. СПб. : Питер. 2021. 400 с.
9. Айвазян С.А. *Методы эконометрики*. Москва : Магистр : ИНФРА-М. 2010. 512 с.

**А.А. ДУДКИН, В.В. ГАНЧЕНКО, А.В. ИНЮТИН,
Е.Е. МАРУШКО**

Объединенный институт проблем информатики
Национальной академии наук Беларуси (ОИПИ НАН Беларуси), Минск
avin@lsi.bas-net.by

НЕЙРОСЕТЕВАЯ МОДЕЛЬ КЛАССИФИКАЦИИ, ОСНОВАННАЯ НА ИСПОЛЬЗОВАНИИ АВТОЭНКОДЕРА И ПОСТРОЕННАЯ ПО АРХИТЕКТУРЕ АНСАМБЛЯ МНОГОСЛОЙНЫХ ПЕРСЕПТРОНОВ*

Для идентификации и классификации объектов на изображениях, полученных с помощью съемочных средств беспилотных летательных аппаратов (БПЛА) и орбитального базирования, предложена нейросетевая модель классификации, основанная на использовании автоэнкодера и построенная по архитектуре ансамбля многослойных персептронов. При выделении информативных признаков дополнительно добавляется цветовая информация, инвариантная к масштабу и поворотам изображения и основанная на построении поканальных гистограмм. Модель реализована с использованием библиотеки Keras. Использование предложенной модели для классификации на четыре класса: «Пожар», «Задымление», «Растительность» и «Строения», позволяет достичь точности классификации выше 99%.

Ключевые слова: автоэнкодер, ансамбль многослойных персептронов, классификация.

Введение

Мониторинг земной поверхности с целью обнаружения стихийных бедствий и оценки их последствий, контроля природопользования и экологической безопасности является актуальной задачей. Ряд стихийных бедствий, таких как паводковые наводнения, лесные пожары и засухи, аварии на техногенных объектах, затрагивают территории приграничных стран.

Для своевременного обнаружения на конкретном участке территории фактов возникновения и развития неблагоприятных явлений, ситуаций и

* Данная работа выполнена при частичной поддержке БРФФИ, проект № Ф21УКРГ-007.

стихийных бедствий необходимо с целью скорейшей ликвидации этих последствий использовать информацию от разных источников: космические снимки, данные аэросъемки, включая полученные с БПЛА, а также специальные данные от наземных средств мониторинга, включая мобильные.

Широкое внедрение информационных систем, основанных на обработке данных дистанционного зондирования Земли (ДЗЗ), получаемых с помощью космических спутников и БПЛА, ставит задачу разработки эффективных методов и алгоритмов обработки изображений, в которых нуждаются потребители для распознавания природно-техногенных объектов в процессе мониторинга окружающей среды.

Постановка задачи

Задачей решаемой представленными нейросетевыми моделями является выделение параметров объектов на изображениях для их идентификации и классификации. Идентификация и классификация объектов осуществляются для участков исходных цветных изображений размером 128×128 пикселей.

Пример кадра видеосъемки БПЛА пожара на нефтебазе приведен на рис. 1.



Рис. 1. Пример кадра видеосъемки БПЛА

Также использовались файлы съемки спутником Landsat 8 в диапазоне, полученном комбинацией красного, синего, зеленого и панхроматическо-

го каналов, и тепловом инфракрасном диапазоне. Данные получены из Sentinel Hub [1]. Разрешение цветных каналов составляет 30 метров на пиксель. Разрешение панхроматического канала – 15 метров на пиксель. Разрешение теплового инфракрасного канала – 100 метров на пиксель.

Классификация осуществляется на четыре класса: «Пожар», «Задымление», «Растительность» и «Строения». Пример изображений для каждого класса приведен на рис. 2.



Рис. 2. Примеры участков изображений для идентификации и классификации

Для расширения набора данных, используемых для обучения моделей, были использованы следующие аугментации (в случайных комбинациях):

- поворот изображения на углы 0, 90, 180 и 270 градусов;
- отражение по вертикали и горизонтали;
- масштабирование на случайную величину из диапазона [0,9; 2].

Описание подхода

Идентификация и классификация участка изображения разделяются на два этапа:

- 1) выделение информативных признаков, позволяющих идентифицировать содержимое изображения;
- 2) выбор класса, которому согласно выделенным признакам, максимально соответствует анализируемый участок изображения.

Основой используемого подхода к выделению признаков является использование нейросетевой модели автоэнкодера, который формирует дескриптор изображения в виде массива из 512 элементов (числа с плавающей запятой). Получаемый массив нормируется по L2-норме.

Автоэнкодеры состоят из двух частей: энкодера g и декодера f . Энкодер переводит входной сигнал в его представление (дескриптор) $h = g(x)$, а декодер восстанавливает сигнал по его коду $x = f(h)$. Автоэнкодер, изменяя g и f , стремится выучить тождественную функцию $x = f(g(x))$, миними-

зируя функционал ошибки $L(x, f(g(x)))$. При этом семейства функций энкодера g и декодера f ограничены так, чтобы автоэнкодер был вынужден отбирать наиболее важные свойства сигнала.

Кодировщик представляет собой набор из трех сверточных блоков с понижением размерности и одного полносвязного слоя. Каждый сверточный блок состоит из двух сверточных слоев (например, Conv2D_1.1 и Conv2D_1.2 для первого блока) и слоя понижения пространственной размерности (например, MaxPooling2D_1 для первого блока). Сверточные слои выполняют функцию выделения признаков заданного размера и формирования карт признаков по одной на каждый фильтр. Полносвязный слой выполняет функцию преобразования полученного набора карт признаков в одномерный вектор чисел с плавающей запятой.

Декодировщик также состоит из одного полносвязного слоя и трех сверточных блоков с повышением размерности. Каждый сверточный блок состоит из слоя повышения пространственной размерности (например, UpSampling2D_2 для первого блока) и двух сверточных слоев (например, Conv2D_4.1 и Conv2D_4.2 для первого блока).

Многозональное изображение может быть представлено в виде трехмерного куба, две оси которого имеют пространственную, а третья – спектральную размерность (непосредственно связанную с излучательной и отражательной характеристиками объекта) [2].

Для получения дескриптора участка исходного цветного изображения размером 128×128 пикселей достаточно подать это изображение на вход автоэнкодера и получить выходные значения указанного скрытого слоя.

Так как вектор размерностью 512 отобразить не представляется возможным, то для вывода данных был использован алгоритм понижения размерности – метод главных компонент.

С помощью указанного метода размерность дескрипторов была уменьшена с 512 до двух, что уже может быть отображено на плоскости.

На рис. 3 приведен пример отображения 16 дескрипторов (для четырех различных групп изображений, включающих различные типы поверхностей).

Текстурные характеристики

Текстурные характеристики выражают разность значений интенсивности соседних пикселей изображения, при этом значения оценок этой разности отличаются для различных типов подстилающей поверхности.

Примеры вычисленных текстурных характеристик приведены в таблице 1.

Таблица 1

Примеры вычисленных текстурных характеристик

Объект	Характеристика	
	ASM	Contrast
Дым	5.262e-03	4.249e+01
Лес	2.215e-04	2.681e+02
Строения	3.915e-04	1.560e+02
Очаг возгорания	2.594e-03	1.656e+02

Вычисление текстурных характеристик снимка выполняется в так называемом «скользящем окне». Размер «скользящего окна» – 4×4 пикселя. Т.е. выбранные текстурные характеристики вычисляются для небольших участков изображения. Значения текстурных характеристик собираются в матрицы, которые преобразовываются к целочисленным значениям в диапазоне от 0 до 255. Полученная матрица представляет собой полутоновое изображение, которое позволяет сравнить значения оценок текстурных характеристик для различных участков изображений.

Текстурные характеристики могут вычисляться на основе полутоновых пространственно-зависимых матриц по каждому из четырех направлений – по горизонтали, по вертикали или по двум диагоналям, с учетом выбранного расстояния d , после чего эти четыре оценки усредняются для получения единой оценки. Расстояние d используется при вычислении матрицы относительных частот $P(i, j, d, a)$ (вычисляется для пары соседних пикселей, разделенных расстоянием d по выбранному направлению a).

Для оценки текстуры используются текстурные характеристики Харалика.

Мультимодальные данные

В литературе рассматривается ряд способов использования мультимодальных данных для глубоких нейронных сетей. В качестве данных различной модальности рассматриваются: цветные изображения, карта глубины, радарные снимки, цифровая модель рельефа, цифровая модель поверхности, данные ультразвуковых датчиков, текстовое описание, аудио- и видеопоследовательности, а также данные с иных спектральных датчиков и их производные признаки (вегетационные индексы) [3–5].




Рис. 3. Расположение двумерных проекций дескрипторов на плоскости в виде миниатюр

Работа с мультимодальными данными направлена на получение лучшего общего представления по сравнению с одномодальными. Поскольку прямая конкатенация извлеченных признаков из данных с различной модальностью часто приводит к неточным результатам, общее представление (дескриптор) может быть улучшено с использованием описанного выше глубокого автоэнкодера. Для этого необходимо, чтобы используемые данные в каждой модальности могли быть представлены в виде карты. Также необходимо согласование координат для данных карт, то есть они должны быть представлены в виде многозонального изображения.

Далее размер входного слоя преобразуется к размеру $128 \times 128 \times N$, где N – количество карт различной модальности. А для выходного сверточного слоя Conv2D_6.2 количество фильтров $Fc = N$. Обучение модели и получение дескриптора не отличается от подхода, описанного выше.

Вариативные информативные признаки

Построение дескрипторов объектов основано на использовании комбинированных информативных признаков многоспектральных изображений. Важной характеристикой признаков является вариативность.

Вариативность – свойство и мера изменчивости объектов, их числовых и нечисловых характеристик, состояний и связей. Локальная вариативность информативных признаков может оцениваться только их текстурными характеристиками.

Алгоритм построения дескрипторов объектов с использованием обученного автоэнкодера включает следующие шаги.

Шаг 1. Получение изображений ДЗЗ, которые включают ближний инфракрасный спектр.

Шаг 2. Вычисление карт информативных признаков многоспектральных изображений (вегетационные индексы NDVI и цветовые признаки).

Шаг 3. Вычисление карт характеристик вариативности (текстурные характеристики Харалика и фрактальные характеристики).

Шаг 4. Комбинирование полученных карт в одну многомерную карту информативных признаков.

Шаг 5. Разбиение многомерной карты на перекрывающиеся участки размером 128×128 .

Шаг 6. Вычисление дескрипторов с использованием автоэнкодера.

При выделении информативных признаков дополнительно добавляется цветовая информация, инвариантная к масштабу и поворотам изображения. Для этого для каждого обрабатываемого участка изображения строится его поканальная гистограмма. При этом для сокращения объема данных применяется квантование значений яркости не на 256 уровней, а на 16. Далее полученные гистограммы объединяются в один массив размером 48 элементов: (16 значений синего канала, 16 значений зеленого канала, 16 значений красного канала). Полученный массив также нормируется по L2-норме.

Таким образом, результатом идентификации является массив из 560 элементов, который и используется для классификации.

Для классификации разработана нейросетевая модель, состоящая из двух многослойных персептронов, объединенных в виде нейросетевого ансамбля. Каждый персептрон в отдельности анализирует входной массив данных, после чего выходные слои формируют взвешенное общее решение по классу входных данных. Сама модель реализована на языке программирования Python с использованием библиотеки Keras [6].

Таким образом, в целом разработанный подход можно представить в виде следующих шагов.

Шаг 1. Берем участок цветного изображения размером 128×128 пикселей.

Шаг 2. Для этого изображения строим дескриптор размерностью 512 элементов, используя разработанный автоэнкодер.

Шаг 3. Для этого же изображения строим набор дополнительных признаков, описывающих цветовые характеристики изображения, представ-

ляющий собой массив из 48 элементов, полученный из поканальной гистограммы, как описано ниже.

Шаг 4. Объединяем полученные на шагах 2 и 3 массивы в один размером 560.

Шаг 5. Полученный объединенный массив отправляем на вход модели классификации, в результате исполнения которой получаем массив из четырех чисел, которые указывают на степень близости изображенного тому или иному классу.

Шаг 6. Индекс, соответствующий максимальному значению массива, полученного на шаге 5, и является искомым индексом класса.

Обучение моделей

Обучение модели классификации:

Функция потерь (loss) – categorical cross entropy [7]:

- размер обучающей выборки: 4000 изображений (не включая аугментацию);
- размер валидационной выборки: 800 изображений (не включая аугментацию);
- результирующая точность на валидационной выборке: 99,19%;
- обучающий алгоритм: Adam [8] с параметрами: $lr = 0,0001$, $beta_1 = 0,9$, $beta_2 = 0,999$, $epsilon = 1 \cdot 10^{-8}$, $decay = 0,0$.

Тестирование

Тестирование осуществлялось на валидационной выборке. При этом оценивалась точность как для каждого класса в отдельности, так и для всех классов в целом. Полученные результаты тестирования приведены в табл. 2.

Из-за несбалансированности классов в исходных данных требуется дополнительная оценка. Данные, полученные в результате, сведены в матрицы неточностей (confusion matrix), приведенные в табл. 3. Значения в матрицах приведены в относительных величинах – количество объектов, принадлежащих классу, к общему количеству объектов всех классов в выборке.

Таблица 2

Результаты тестирования сегментаторов

Классы	Точность, %
Задымление	86,9
Растительность	99,7
Строения	100
Пожар	98,9
Общая точность	99,19

Таблица 3

Матрицы неточностей

Предсказанные классы	Реальные классы			
	Задымление	Растительность	Строения	Пожар
Задымление	0,285	0,003	0,039	0,001
Растительность	0,000	0,222	0,001	0,000
Строения	0,000	0,000	0,224	0,000
Пожар	0,000	0,002	0,001	0,224

Для оценки качества классификации были вычислены соответствующие значения точности (precision), полноты (recall) и F1-меры [8] (см. Таблицу 4).

Таблица 4

Значения точности (precision), полноты (recall) и F1-меры

Классы	Precision	Recall	F1
Задымление	0,869	1,000	0,930
Растительность	0,997	0,981	0,989
Строения	1,000	0,848	0,918
Пожар	0,989	0,994	0,991

Наибольшее количество ошибок возникало на участках, соответствующих границе задымления и пожара, а также в случае горения строений.

Выводы

Для идентификации и классификации объектов на изображениях, полученных с помощью съемочных средств БПЛА и орбитального базирования, предложена нейросетевая модель классификации, основанная на использовании оригинального автоэнкодера и построенная по архитектуре ансамбля многослойных персептронов.

Получаемые дескрипторы представляют собой массив из 512 чисел с плавающей запятой. В качестве основы для построения дескрипторов использован нейросетевой автоэнкодер, архитектура которого зависит от модальности и цветности исследуемых данных. Отличительными чертами разработанных моделей является использование как многомодальных и

разноцветных данных, так и использование дополнительных информативных признаков вариативности данных. Для оценки вариативности данных использованы текстурные признаки Харалика, построенные для локальных участков изображения. При выделении информативных признаков дополнительно добавляется цветовая информация, инвариантная к масштабу и поворотам изображения и основанная на построении поканальных гистограмм.

Модель реализована с использованием библиотеки Keras. Использование предложенной модели для классификации на четыре класса: «Пожар», «Задымление», «Растительность» и «Строения» позволяет достичь точности классификации выше 99%.

Список литературы

1. https://apps.sentinel-hub.com/eo-browser/?zoom=13&lat=50.20921&lng=30.23931&themeId=DEFAULT-THEME&visualizationUrl=https%3A%2F%2Fservices.sentinel-hub.com%2Fogc%2Fwms%2Ffe35192fe-33a1-41f3-b798-b755e771c5a5&datasetId=AWS_LOTL1&fromTime=2015-06-09T00%3A00%3A00.000Z&toTime=2015-06-09T23%3A59%3A59.999Z&layerId=1_TRUE_COLOR
2. Орешкина Л. В. Обнаружение и распознавание класса объектов на многозональных изображениях дистанционного зондирования // Информатика. 2019. №. 2 (6). С. 79-85.
3. Kuga R. [et al.] Multi-task learning using multi-modal encoder-decoder networks with shared skip connections // Proceedings of the IEEE International Conference on Computer Vision Workshops. 2017. P. 403-411.
4. Chen K. [et al.]. Deep Semantic Segmentation of Aerial Imagery Based on Multi-Modal Data // IGARSS 2018–2018 IEEE International Geoscience and Remote Sensing Symposium. IEEE, 2018. P. 6219-6222.
5. Feng D. [et al.] Deep multi-modal object detection and semantic segmentation for autonomous driving: Datasets, methods, and challenges // IEEE Transactions on Intelligent Transportation Systems. 2020.
6. <https://keras.io/api/optimizers/adam/>
7. https://www.tensorflow.org/api_docs/python/tf/keras/metrics/categorical_crossentropy
8. Kingma, D. P., Ba, J. Adam: A Method for Stochastic Optimization // 3rd International Conference for Learning Representations, San Diego, 2015. V. 1412. P. 6980.
9. Marina Sokolova, Nathalie Japkowicz, Stan Szpakowicz. Beyond accuracy, F-score and ROC: a family of discriminant measures for performance evaluation // Advances in Artificial Intelligence, 19th Australian Joint Conference on Artificial Intelligence, 2006. Hobart, Australia, December 4-8, 2006. P. 1015–1021.

В.И. ТЕРЕХОВ, Д.О. ИШКОВ

Московский государственный технический университет им. Н. Э. Баумана
terekchow@bmstu.ru

ПОИСК НЕЙРОСЕТЕВОЙ АРХИТЕКТУРЫ ДЛЯ РЕШЕНИЯ ЗАДАЧИ АППРОКСИМАЦИИ МЕТОДА ДИНАМИЧЕСКОГО АНАМОРФИРОВАНИЯ

В статье проведён поиск оптимальных конфигураций трёх нейросетевых архитектур двумя методами. Нейронная сеть решает задачу аппроксимации метода анаморфирования. Собран набор данных, состоящий из визуальных изображений и нерегулярных растров преобразований. Исследованы различия и сходства между генетическим алгоритмом и байесовским поиском. Оба метода находят оптимальные конфигурации со сравнимой скоростью, при этом найденные конфигурации генетического алгоритма более разнообразные.

Ключевые слова: *когнитивная визуализация, метод динамического анаморфирования, поиск нейросетевой архитектуры, генетический алгоритм, байесовский поиск, свёрточная нейронная сеть, визуальный трансформер.*

Введение

Анаморфоза определяется как преобразование визуального образа, основанного на евклидовой метрике, в другой образ, построенный на основе метрики критерия, определенного лицом, принимающим решение (ЛПР). Преобразованное таким образом изображение способно предложить новые идеи и варианты ЛПР. В этом случае иллюстративная функция изображения превращается в когнитивную функцию. В связи с этим возникает проблема нахождения конформного преобразования, инвариантного к системе координат [1, 2]. Для получения такого преобразования необходимо решить систему дифференциальных уравнений. На данный момент существует множество работ, в частности работы [3–5], посвящённые нахождению квазиоптимального решения методом последовательных приближений. В предыдущей работе авторов [6] была предложена модификация алгоритма, которая позволяет достичь более точного решения. Как показал анализ полученных результатов, большое число итераций предложенного алгоритма сказывается на итоговом времени работы алгоритма и ограничивает его оперативное применение.

Авторами было принято решение подобрать такую архитектуру нейронной сети, которая будет иметь минимальное время работы и получать максимально качественный результат. В связи с этим возникает задача поиска оптимальной архитектуры нейронной сети (НС) среди существующего множества различных архитектур. В работе проведён подбор гиперпараметров для трёх популярных архитектур: многослойного персептрона (MLP), свёрточной нейронной сети (CNN) и визуального трансформера (ViT), подробно описанного в работе [7].

Постановка задачи и описание метода

Под качеством модели будем понимать то, насколько хорошо модель решает задачу аппроксимации результата работы алгоритма [6]. Поскольку на выходе модели ожидается получить координаты сетки преобразования, то определим целевую функцию как близость значений координат к истинным, полученным алгоритмом [6]. Однако это косвенная целевая функция, т.к. первоначально задача нахождения конформного преобразования методом динамического анаморфирования рассматривает площади ячеек как целевой критерий. Таким образом, можем определить функцию потерь (она же и будет функцией качества) как взвешенную сумму (1) косвенной целевой функции и первоначальной:

$$L = \alpha \times d_1(y_{pred}, y_{true}) + \beta \times d_2(S_{pred}, S_{true}), \quad (1)$$

где α – влияние косвенной целевой функции по координатам, β – влияние непосредственной целевой функции площадей ячеек, d_1 – мера расстояния между предсказанными координатами y_{pred} и фактическими y_{true} , d_2 – мера расстояния между предсказанными площадями S_{pred} и теоретическими S_{true} .

Рассмотрим наиболее распространённые способы поиска гиперпараметров НС. Поиск полным перебором (Grid Search) предполагает наличие фиксированного набора значений каждого гиперпараметра. Такой метод поиска гарантированно находит оптимальное решение в существующем множестве комбинаций параметров. Зачастую поиск полным перебором неосуществим из-за комбинаторного взрыва, возникающего при росте пространства поиска. Случайный поиск (Random Search) предлагает выбирать набор гиперпараметров случайным образом, равновероятно выбирая значения каждого параметра из множества заданных его значений. Тем самым пространство поиска будет покрыто равномерно. На практике такой подход находит решение, близкое к оптимальному, быстрее, нежели метод полного перебора. Недостатком данного подхода является то, что результаты промежуточных проверок сочетаний параметров не учитыва-

ются в следующих итерациях. Байесовский поиск, предложенный в работе [8], обучает на каждой итерации параметрическую модель, принимающую параметры на вход и прогнозирующую функцию качества в новых точках пространства поиска. При этом обязательным условием является указание априорной функции распределения вероятностей каждого гиперпараметра. История проверенных сочетаний хранится в оперативной памяти, что может привести к негативным последствиям в случае аварийного завершения работы вычислительного устройства. Генетический алгоритм успешно применялся для нахождения архитектуры НС ранее в работе [9]. Исходя из сказанного, для поиска гиперпараметров НС предлагается использовать генетический алгоритм и байесовский поиск.

Описание и сбор данных

Для обучения моделей в заданной конфигурации используется заранее сгенерированный набор данных. Каждый пример из набора является кортежем из двух элементов: индексы анаморфирования и координаты нерегулярного растра конформного преобразования. Координаты рассчитываются при помощи алгоритма из работы [6]. Поскольку координата – это пара двух чисел, то отдельно необходимо предсказывать значения по оси абсцисс и по оси ординат. Для сетки размером 64 на 64 ячейки входных признаков будет 4096, а выходных 8192.

Для генерации синтетических примеров использовалась библиотека на Python для векторной графики и работы с изображениями Pillow. При генерации карт индексов анаморфирования применялись различные геометрические формы и фигуры. Данные фигуры генерировались со случайными координатами и в случайном масштабе. На одной карте могли присутствовать от одной до трёх из перечисленных форм. При этом оттенки серого создаваемых объектов могли не совпадать, что так же вносило разнообразие в алгоритм генерации. Фон при генерации тоже имел разные оттенки. С вероятностью 50% цвета получаемых изображений инвертировались.

В ходе генерации могли возникать неудачные примеры, которые желательно исключить из обучающей выборки. Например, фигура могла появиться на краю холста или генерируемый треугольник мог получиться вырожденным. Для фильтрации таких аномальных примеров предлагается использовать достаточно простой подход: фильтрация по проценту заполненных пикселей. На сгенерированные примеры применяется адаптивный фильтр Гаусса, который позволяет получить черно-белые маски. После чего подсчитывается процент белых пикселей от общей массы. Предлага-

ется удалять из обучающей выборки примеры, в которых процент белых пикселей меньше 20% и больше 80%.

Помимо синтетических примеров в выборку было добавлено также некоторое число вручную созданных примеров. Всего вместе получено 44 902 пар карт и сеток преобразования. На рис. 1 представлено несколько примеров вручную созданных входных данных для нейронной сети и ожидаемые выходные данные в виде сетки преобразований разрешением 64 на 64 пикселя.




Рис. 1. Примеры карт индексов анаморфирования и соответствующих им сеток преобразования из сформированной обучающей выборки

Поиск оптимальной архитектуры модели

Определим пространство поиска для каждого типа модели. Для MLP будем варьировать следующие параметры: функцию потерь, функцию активации скрытого слоя, ранг факторизации весов параметров, размер эмбединга входного слоя и L2-регуляризацию. Общее число возможных сочетаний параметров при этом составляет 141 тыс. комбинаций. Для CNN будем варьировать следующие параметры: функцию потерь, функцию активации скрытого слоя, ранг факторизации весов параметров, L2-регуляризацию, число свёрточных слоёв, множитель числа фильтров, наличие соединения с пробросом [10], тип пулинга. Всего получим 4,8 млн возможных комбинаций параметров. Для поиска оптимальной архитектуры ViT используем следующие параметры: функцию потерь, функцию активации скрытого слоя, число слоёв внимания, число голов внимания, размер скрытого слоя внимания, размер патча изображения,

регуляризация Dropout, L2-регуляризация. В общей сложности насчитывается 54,4 млн сочетаний гиперпараметров.

Для реализации генетического алгоритма было написано собственное решение на языке программирования Python. Для получения генерации случайных чисел, необходимых для предварительной стадии генетического алгоритма, а также для этапов скрещивания и мутации использовалась библиотека NumPy. В качестве хромосомы особи выступает упорядоченный массив с реализацией гиперпараметров. Изначально все значения гиперпараметров равновероятны. В процессе поиска вероятность выбора значения изменяется в зависимости от частоты его встречаемости в наборе лучших особей. При таком подходе не учитывается близость значений гиперпараметров, они рассматриваются как дискретное неупорядоченное множество. Качество особи совместно с её конфигурацией архитектуры заносилось в текстовый файл. Под качеством тут понимается функция приспособленности (1).

Для реализации байесовского поиска использовалась библиотека HyperOpt, в основе работы которой лежит идея, описанная в статье [8]. Данный подход позволяет задавать гиперпараметры как элементы дискретного множества, так и как непрерывные величины. Поэтому приведённые выше оценки размеров пространства поиска сильно занижены. Данный подход учитывает близость признаков, но не учитывает их взаимодействие, как это делает генетический алгоритм. Проблема сохранения истории проверяемых гиперпараметров на постоянное запоминающее устройство, упомянутая ранее, была решена путём сериализации структуры данных Trials библиотеки HyperOpt. Сериализация на постоянное устройство проводилась при помощи стандартной библиотеки Pickle. Таким образом, главный недостаток байесовского поиска был устранён. Это позволяет выполнять поиск не с самого начала в случае аварийного завершения работы. В качестве примера таких сценариев можно привести нехватку оперативной памяти, вызванной слишком тяжёлой архитектурой нейронной сети, а также перебои с электричеством.

В качестве библиотеки для обучения нейронных сетей использовалось решение от компании Google, Tensorflow. В начале поиска производятся тестовые обучения моделей длительностью две эпохи с шагом обучения $2 \cdot 10^{-3}$ на наборе данных, полученных в предыдущих разделах. После 200 итераций каждая модель обучается уже 20 эпох с шагом обучения $2 \cdot 10^{-4}$, а затем шаг уменьшается на порядок и модель обучается ещё 5 эпох. В качестве оптимизатора градиентного спуска используется Adam. Для каждой архитектуры было проведено порядка семи сотен итераций.

Анализ результатов

Динамика изменения качества моделей в течение работы генетического алгоритма и байесовского поиска показана на рис. 2. Здесь LinReg обозначен частный случай многослойного персептрона, когда функция активации скрытого слоя является линейной. Как видно из графика, первое место по качеству занимает архитектура ViT, второе – CNN. В табл. 1 приведены характеристики каждой разновидности лучшей модели по итогам проведённого поиска двумя способами. Здесь под качеством понимается мера близости между площадью ячейки сетки преобразования и соответствующим ей индексом анаморфирования. Площадь ячейки по заданным координатам рассчитывается по формуле Гаусса. Данная площадь является нормированной, поэтому сравнение целесообразно проводить не с первоначальным индексом анаморфирования, а с нормированным относителем среднего значения по всей карте показателей. В качестве такой меры близости было решено выбрать коэффициент детерминации.




Рис. 2. Качество лучшей модели в течение поиска: а) генетический алгоритм; б) байесовский поиск

Таблица 1

Характеристики оптимальных моделей

Модель	Качество, %	Число параметров	Время прохода по датасету, с
MLP	75,798	4 728 000	4,009±0,103
CNN	78,301	4 473 896	5,257±0,211
ViT	80,798	5 833 776	4,914±0,092

Рассмотрим динамику выбираемых параметров разными подходами для гиперпараметров архитектур. Результаты для числа слоёв свёрточной

нейронной сети приведены на рис. 3. Графики следует трактовать образом, аналогичным спектрограмме звука: вдоль одной оси откладывается время, вдоль второй – отмечаются значения параметров, а вдоль вертикальной – спектральная плотность мощности. В плоскости среза перпендикулярно временной оси в месте максимального значения спектральной плотности мощности находится наиболее часто выбираемое значение параметра в данный временной интервал. Как можно видеть из результатов, разные подходы сходятся к разным значениям параметров. Заметим, как байесовский поиск исследует одну гипотезу оптимальных параметров в один момент времени, а генетический алгоритм проверяет несколько конкурирующих гипотез друг с другом. Так, по результатам генетического поиска в нашем распоряжении оказывается три конкурирующие гипотезы оптимальных моделей для числа свёрточных слоёв 3, 5 и 7. В то же время байесовский поиск выдаёт лишь одну гипотезу для числа свёрточных слоёв 4. Это означает, что предложенный генетический алгоритм подбирает множество некоррелированных между собой особей, когда как байесовский поиск на выходе получает множество сильно коррелированных между собой вариантов.




Рис. 3. Трёхмерные спектрограммы числа слоёв CNN: а) генетический алгоритм; б) байесовский поиск

Рассмотрим восстановление индексов анаморфирования тремя подобранными моделями. Реконструкция приведена на рис. 4. Как можно видеть из рисунка, свёрточная нейросеть получает более чёткую реконструкцию на синтетических примерах. Результат CNN оказался лучше, несмотря на то, что ViT обходит данную модель по качеству. Вероятно, выбранный критерий качества не налагает штраф за размытость восстановленных индексов анаморфирования. На рис. 5 показано соотношение сложности свёрточных моделей к достигаемому качеству. Пунктирная

линия проведена по эффективным по Парето конфигурациям параметров. Как можно видеть из графиков, байесовский поиск проигрывает в изучении слабо оптимальных параметров и сосредоточен на получении максимального качества. А генетический алгоритм, благодаря этапам мутации и скрещивания, получает более разнообразные комбинации параметров. Площадь под кривой Парето-оптимальных вариантов генетического алгоритма больше площади под кривой байесовского поиска. В то же время эффект «скученности» байесовского поиска позволяет найти чуть лучшую комбинацию гиперпараметров для моделей с 2–3 миллионами нейронов.





ИСХОДНЫЙ ПРИМЕР	РЕКОНСТРУКЦИЯ РЕЗУЛЬТАТА АЛГОРИТМА [6]	MLP	CNN	ViT
				
				

Рис. 4. Реконструкция индексов анаморфирования тремя моделями




Рис. 5. Оптимальность по Парето для CNN по всем реализациям: а) генетический алгоритм; б) байесовский поиск

Заключение

Полученные результаты двумя методами позволили получить оптимальные по Парето архитектуры нейронных сетей для задачи аппроксимации метода динамического анаморфирования. Лучшей оказалась архитектура CNN. Генетический алгоритм и байесовский поиск имеют равную

степень предпочтительности по скорости нахождения гиперпараметров с небольшим преимуществом у байесовского поиска. Гибридный генетический алгоритм компенсирует это более обширным исследованием пространства поиска при одинаковом бюджете на количество испытаний. Гибридный алгоритм проверяет пару конкурирующих между собой гипотез (One-vs-One), тем самым реализуя естественный отбор. Байесовский поиск, напротив, проверяет лишь одну гипотезу за раз и сравнивает её со всеми остальными (One-vs-Rest). Это различие делает байесовский поиск своего рода «жадным» алгоритмом, что негативно сказывается на изучении пространства поиска. Генетический алгоритм проводит отбор с помощью попарных сравнений особей между собой, а байесовский алгоритм моделирует функцию правдоподобия по экспериментальным данным, которые могут содержать ошибки.

Список литературы

1. Gusein-Zade S.M., Tikunov V.S. Anamorphoses: What Are They. 1999.
2. Dougenik J.A., Chrisman N.R., Niemeyer D.R. An algorithm to construct continuous area cartograms // The Professional Geographer. 1985. V. 37, N 1. P. 75-81.
3. Terekhov V.I. [et al.]. Cognitive Visualization in Management Decision Support Problems // Optical Memory and Neural Networks. 2019. V. 28, N 1. P. 27-35.
4. Terekhov V.I., Chernenky I.M. Making a Decision Using Anamorphing Approach // Information-Measurement and Control Systems. 2016. V. 12, P. 132-139.
5. Berezkin D.V., Terekhov V.I. Anamorphing Approach for Modelling and Evaluation of Geopolitical Boundaries Changes // Artificial Intelligence and Decision Making. 2017. No. 3, P. 3-9.
6. Ishkov D.O., Goryachkin B.S., Terekhov V.I. Processing and Visualization of Tomography Signal with AI: Decision Making on COVID-19 // 2022 4th International Youth Conference on Radio Electronics, Electrical and Power Engineering (REEPE). IEEE, 2022. P. 1-6.
7. Dosovitskiy A. [et al.]. An image is worth 16x16 words: Transformers for image recognition at scale // arXiv preprint arXiv:2010.11929. 2020
8. Bergstra J., Yamins D., Cox D. Making a science of model search: Hyperparameter optimization in hundreds of dimensions for vision architectures // International conference on machine learning. PMLR, 2013. P. 115-123
9. Lu Z. [et al.]. Nsga-net: neural architecture search using multi-objective genetic algorithm // Proceedings of the genetic and evolutionary computation conference. 2019. P. 419-427.
10. He K. [et al.]. Deep residual learning for image recognition // Proceedings of the IEEE conference on computer vision and pattern recognition. 2016. P. 770-778.

Э.З. КАРИМОВ¹, В.Р. ШИРОКИЙ², И.Н. МЯГКОВА²¹ Московский государственный университет им. М.В. Ломоносова² Научно-исследовательский институт ядерной физики им. Д.В. Скобельцына МГУ им. М.В. Ломоносова

karimov.ez19@physics.msu.ru

**ПРИМЕНЕНИЕ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ
ДЛЯ ДОМЕННОЙ АДАПТАЦИИ ДАННЫХ КОСМИЧЕСКИХ
АППАРАТОВ**

В работе рассматривается задача доменной адаптации данных, используемых для прогнозирования геомагнитного Dst-индекса с помощью методов машинного обучения. Доменная адаптация необходима при переходе с данных одного космического аппарата (КА) на данные другого. Рассматриваются и сравниваются несколько методов перевода данных из домена КА DSCOVER (Deep Space Observatory) в домен КА ACE (Advanced Composition Explorer). Показано, что доменная адаптация данных позволяет повысить качество прогнозирования.

Ключевые слова: *временной ряд, доменная адаптация, прогнозирование.*

Введение

Для эффективного прогнозирования временных рядов (ВР) методами машинного обучения необходимо наличие длинных стационарных или квазистационарных ВР входных данных, по возможности получаемых из одного источника по всей длине ВР. Это может представлять проблему, когда источником данных являются приборы, установленные на космических аппаратах (КА), и по техническим причинам необходим переход с данных одного КА на данные другого.

Прогнозирование явлений космической погоды, таких как геомагнитные возмущения и изменение потоков релятивистских электронов внешнего радиационного пояса Земли (РЭ ВРПЗ), является важной практической задачей, и с развитием глобальной цифровой индустрии, как на Земле, так и в космосе, ее актуальность будет расти [1, 2].

Поскольку универсальных физических моделей, позволяющих осуществлять прогнозирование амплитуды геомагнитных возмущений и радиационных условий в околоземном космическом пространстве, на данный момент не создано, мы используем для прогнозирования искусственные нейронные сети (ИНС). Поскольку основным источником и геомаг-

нитных возмущений и вариаций потоков РЭ ВРПЗ являются процессы в гелиосфере, которые в свою очередь характеризуются параметрами межпланетного магнитного поля (ММП) и солнечного ветра (СВ), в качестве входных данных при прогнозировании показателей космической погоды (Dst-индекс, Кр-индекс, потоки РЭ ВРПЗ) обычно используются оперативные данные измерений параметров ММП и СВ, полученные в точке Лагранжа L1 системы Солнце–Земля, например [3–5].

Dst-индекс

В настоящее время для анализа состояния магнитосферы Земли часто используется Dst-индекс (Disturbance Storm Time index). Dst-индекс представляет собой осесимметричную относительно геомагнитного диполя компоненту возмущенного магнитного поля и определяется на основе измерений магнитного поля на четырёх наземных приэкваториальных станциях. На каждой станции определяется величина возмущения магнитного поля. Dst определяется как среднее по долготе возмущение, приведенное к экватору. По факту данный индекс является мерой изменения поля из-за кольцевых токов, возникающих в магнитосфере во время магнитных бурь. С ростом интенсивности бури значения Dst-индекса становятся отрицательными, а его амплитуда увеличивается.

Используемые параметры

Для прогнозирования значений индекса Dst при помощи ИНС нами используются следующие данные:

- данные о величине ММП – покомпонентно (B_x , B_y , B_z) и $|B|$ (модуль ММП);
- данные о параметрах плазмы СВ: скорость СВ (v), плотность протонов (n_p);
- данные об измеренных ранее значениях индекса Dst;
- информация о часе суток и сутках года, представленная в виде значений синуса и косинуса с суточным и годовым периодами.

Источники данных

На данный момент на так называемых гало-орбитах вокруг точки Лагранжа L1 между Солнцем и Землёй находится несколько КА. Для определения параметров СВ и ММП чаще всего используют данные с КА ACE (Advanced composition explorer) [6] и DSCOVR (Deep Space Observatory) [7]. На борту указанных КА расположено множество различных датчиков: магнитометр, чаша Фарадея, которая измеряет потоки заряженных частиц, электростатический анализатор и множество других. КА ACE предоставляет

данные с 1997 года, и в 2024 году запланировано его выведение из эксплуатации. Также данный КА имеет проблему с поставкой данных в режиме реального времени, и они получаются с большими пропусками. КА DSCOVР был запущен в 2015 году и находится практически в той же точке пространства. Поэтому задача адекватного отображения данных из домена ACE в домен DSCOVР является весьма актуальной для обеспечения возможности работы с длинным временным рядом приемлемого качества.

Постановка задачи

Для прогноза Dst-индекса используется многослойный персептрон, обученный на данных с КА ACE, так как их достаточное количество (порядка 200 000 примеров). Но в данных КА ACE в режиме реального времени по техническим причинам стали появляться 12-часовые интервалы, измеряемые значения в которых отсутствуют. Этого нет в архивных записях данных, поставляемых разработчиками КА спустя 2–3 суток, что позволяет предположить, что измерительная аппаратура исправна, а технические проблемы возникли с функционированием каналов связи. Данная особенность делает прогноз космической погоды в режиме реального времени с использованием данных с КА ACE весьма затруднительным. Так как для прогноза Dst-индекса мы используем сами параметры и все их предыдущие значения за 24 часа, то каждый пропуск делает непригодными к использованию в машинном обучении 25 соседствующих примеров. Это сильно уменьшает общее количество доступных для использования примеров, а также приводит к возникновению интервалов времени, в которых прогноз может отсутствовать. Данных с КА DSCOVР пока недостаточно, чтобы обучить новую нейронную сеть для качественного прогноза Dst-индекса (около 40 000 примеров). Учитывая это, необходимо найти способ перевода в домен КА ACE данных из домена КА DSCOVР, которые описанным выше недостатком не обладают и могут использоваться для онлайн-прогнозирования.

Обработка данных

Для обработки временного ряда мы будем использовать так называемое погружение (топологическое вложение) временного ряда, смысл которого – включение информации о нескольких предыдущих значениях каждой компоненты временного ряда в каждый пример. Погружение будем производить на 24 часа. Также для всех данных производится линейная интерполяция пропусков длительностью до 12 отсутствующих значений подряд.

Методы

Для перевода данных из одного домена в другой будем использовать два способа отображения данных. Первый способ можно назвать «один в одного», когда единственный преобразуемый параметр переводится в соответствующий параметр другого домена. Второй – «все в одного», когда для получения значения искомого параметра на вход преобразующего алгоритма подаются все используемые параметры в исходном домене.

Для осуществления преобразования использовались следующие алгоритмы: линейная регрессия и многослойный персептрон. Параметры персептрона: 1 скрытый слой, 10 нейронов, функция активации – Relu, размер минипакета (батча) – 100, алгоритм обучения – стохастический градиентный спуск (SGD).

Критерии оценки

Для сравнения результатов будем использовать среднее квадратичное отклонение (СКО):

$$S = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - x_{\text{ист}})^2}. \quad (1)$$

Результаты

Данные были разделены на тренировочный и тестовый наборы в пропорции 85 : 15 соответственно. Тренировочный набор использовался для обучения алгоритма преобразования, а тестовый – для оценки результата на независимых данных.

На рис. 1-3 приведены результаты преобразования при помощи многослойного персептрона (MLP) и линейной регрессии (LR) без погружения временного ряда (depth = 0) и с погружением на 24 часа (depth = 24).




Рис. 1. Результат перевода для x- и y- компонент вектора ММП




Рис. 2. Результат перевода для z-компоненты и модуля ММП




Рис. 3. Результат перевода для плотности и скорости СВ

Правый столбец на всех рисунках показывает SKO между значениями соответствующей переменной в разных доменах без перевода.

Аналогичные результаты были получены отдельно для различных фаз магнитных бурь: 0 – бури нет, 1 – внезапное начало, 2 – главная фаза, 3 – фаза релаксации (рис.4–9).




Рис. 4. Результат перевода x компоненты ММП с учётом фаз бури




Рис. 5. Результат перевода у компоненты ММП с учётом фаз бури




Рис. 6. Результат перевода z компоненты ММП с учётом фаз бури




Рис. 7. Результат перевода модуля ММП с учётом фаз бури




Рис. 8. Результат перевода плотности СВ с учётом фаз бури




Рис. 9. Результат перевода скорости СВ с учётом фаз бури

Результаты оказались разными для параметров ММП и для параметров СВ. Для компонент и модуля ММП линейная регрессия показала лучшие результаты, чем персептрон, что может быть обусловлено схожестью характеристик магнетометров, установленных на обоих КА, в результате чего оказалось достаточно линейного преобразования. При этом использование других входных признаков (подход «все в одного») оказалось оправданным только для компоненты V_y . Для модуля ММП наиболее эффективным оказался самый простой подход «один в одного».

Требуемое отображение для параметров СВ оказалось нелинейным, в результате чего персептрон показал лучшие результаты, чем линейная регрессия. При этом наиболее сложным оказалось необходимое преобразование для плотности СВ, для которой заметный выигрыш дал подход «все в одного». Для скорости СВ оба подхода дали одинаковые результа-

ты в пределах погрешности, однако оказалось оправданным использование погружения временного ряда на 24 часа.

Менее очевидными оказались результаты, полученные отдельно для разных фаз магнитной бури. Сложность фазы для прогнозирования оказалась напрямую не связана со сложностью доменной адаптации. Наиболее сложная для прогнозирования главная фаза бури (тип 2) оказалась для доменной адаптации сравнимой по эффективности с фазой 0 (нет бури) и фазой 3 (фаза релаксации); в свою очередь эффективность доменной адаптации для фаз 0 и 3 почти для всех переменных оказалась сравнимой. Наибольшую сложность для доменной адаптации представляет фаза 1 (внезапное начало), что может быть связано с тем обстоятельством, что данная фаза присутствует не во всех бурях, и число примеров, принадлежащих данному классу, оказалось минимальным. Исключение составило преобразование для скорости СВ, что может свидетельствовать о специфике статистики значений скорости СВ на фазе 1.

Для проверки влияния доменной адаптации входных данных на качество прогнозирования Dst индексная нейронная сеть, прогнозирующая значение Dst-индекса на час вперёд, была обучена на трёх массивах данных: данных с KA ACE, данных с KA DSCOVER и данных с KA DSCOVER, адаптированных в домен KA ACE. Использовались следующие параметры нейронной сети: 1 скрытый слой, 20 нейронов, логистическая функция активации, размер батча 100, алгоритм обучения – стохастический градиентный спуск (SGD). Перевод данных DSCOVER в домен ACE осуществлялся для каждого признака оптимальным для него методом (рис. 1–3).

Каждая из сетей после обучения применялась к четырём массивам данных: 1) данные с KA ACE, полученные в реальном времени (и содержащие большое количество пропусков); 2) данные с KA ACE, полученные от источника через 2-3 дня (пропуски в которых были в основном заполнены); 3) данные с KA DSCOVER; 4) данные с KA DSCOVER, адаптированные к домену ACE. Результаты представлены на рис. 10.

Видно, что обе сети, обученные в домене ACE (на данных ACE и на данных DSCOVER, адаптированных в домен ACE), показали наихудшие результаты на исходных данных DSCOVER и наилучшие – на данных DSCOVER, адаптированных к домену ACE, что свидетельствует об эффективности доменной адаптации как средства повышения качества нейросетевого прогнозирования индекса Dst. Сеть, обученная на данных DSCOVER, показала наилучший результат на данных того же типа, что свидетельствует о целесообразности перехода к работе с данными DSCOVER после того как они накопятся в достаточном количестве.




Рис. 10. Результат прогнозирования Dst-индекса на различных тестовых данных при обучении на данных различных типов

Вывод

Использование доменной адаптации позволяет эффективно использовать данные нового КА с малым сроком работы совместно с данными КА, для которого имеется массив данных за длительный период. По мере накопления данных с нового КА рекомендуется их использование.

Список литературы

1. McGranaghan R.M., Camporeale E., Georgoulis M. & Anastasiadis A. Space Weather research in the Digital Age and across the full data lifecycle: Introduction to the Topical Issue // J. Space Weather Space Climate. 2021. V. 11. Art. 50. <https://doi.org/10.1051/swsc/2021037>.
2. Лазутин Л.Л. Мировые и полярные магнитные бури. Москва : МГУ, 2012.
3. Myagkova I., Shiroky V., Dolenko S., Prediction of geomagnetic indexes with the help of artificial neural networks // E3S Web of Conferences. 2017. V. 20. Art. 02011.
4. Ефиторов А.О., Мягкова И.Н., Широкий В.Р., Доленко С.А. Прогнозирование Dst-индекса, основанное на методах машинного обучения // Космические исследования. 2018. Т. 56, № 6. С. 353–364.
5. Мягкова И.Н. и др. Краткосрочное и среднесрочное прогнозирование потоков релятивистских электронов внешнего радиационного пояса Земли методами машинного обучения // Метеорология и гидрология. 2021. № 3. С. 47–57.
6. <https://www.nasa.gov/ace/>
7. <https://solarsystem.nasa.gov/missions/DSCOVR/in-depth/>

Л.Б. ЛИТИНСКИЙ

Федеральный научный центр Научно-исследовательский институт системных исследований Российской академии наук, Москва
litin@mail.ru

**ОПЫТ ОБРАБОТКИ СПЕКТРОГРАММ ВЫДОХА
ДЛЯ ПРОБНОЙ ГРУППЫ ПАЦИЕНТОВ МЕТОДОМ
ГЛАВНЫХ КОМПОНЕНТ***

В работе изложены предварительные результаты обработки пробного фрагмента большого массива медицинских данных. Основная задача медицинского исследования – научиться распознавать по спектрограмме выдоха пациента наличие у него тех или иных заболеваний (или предрасположенности к ним). Методом главных компонент обработана пробная матрица данных, оценена степень разделимости различных классов.

Ключевые слова: *спектрограмма выдоха, метод главных компонент, центроиды классов.*

Введение

Исходные данные представляют собой прямоугольную $(n \times m)$ -матрицу, которая содержит информацию об n пациентах, где каждый пациент описывается числовыми значениями m параметров:

$$\mathbf{X} = \begin{pmatrix} x_1^{(1)} & \cdots & x_1^{(m)} \\ x_2^{(1)} & \cdots & x_2^{(m)} \\ x_3^{(1)} & \cdots & x_3^{(m)} \\ \vdots & \vdots & \vdots \\ x_n^{(1)} & \cdots & x_n^{(m)} \end{pmatrix} : \quad (1)$$

i -й пациент задается m -мерной вектор-строкой $x_i = (x_i^{(1)}, \dots, x_i^{(m)})$, $i = 1, 2, \dots, n$, а реализация значений j -го параметра на совокупности n

* Настоящая работа выполнена в рамках государственного задания по проведению фундаментальных научных исследований по теме «Исследование нейроморфных систем обработки больших данных и технологии их изготовления» № FNEF-2022-0003.

объектов – говоря кратко, j -й параметр, – задается n -мерным вектор-столбцом $x^{(j)} = (x_1^{(j)}, \dots, x_n^{(j)})^+$, $j = 1, 2, \dots, m$. В матрице, с которой работали мы, число параметров m было равно 44, а число пациентов $n = 72$.

Первые 37 пациентов – больные с кардиологическими проблемами, вторая половина (35 пациентов) – с онкологическими проблемами. В дальнейшем, чтобы оторваться от медицинской конкретики, будем говорить об объектах из первого или из второго классов.

Мы не будем обсуждать природу и характер параметров, которыми описываются пациенты. Эти параметры получают в результате довольно сложной (и не до конца устоявшейся) процедуры обработки спектрограмм выдоха пациента. В данном сообщении этот вопрос несущественен: мы излагаем основные принципы обработки и первые результаты. Как обычно, все параметры приведены к единому масштабу: вектор-столбцы центрированы на ноль и нормированы на единичную дисперсию:

$$\forall j: \sum_{i=1}^n x_i^{(j)} = 0, \quad \frac{1}{n} \sum_{i=1}^n (x_i^{(j)})^2 = 1. \quad (2)$$

Предобработка

В первую очередь следовало проверить – нет ли среди имеющихся 44 параметров таких, по которым наши объекты хоть сколь-нибудь разделяются на два класса. Иными словами, пытались отыскать такой параметр, по которому объекты из первого класса группировались бы на одном интервале, а объекты из второго класса – на другом интервале и интервалы не пересекались бы. На рис. 1 показаны гистограммы распределения всех 72 объектов по первым 16 параметрам. Гистограмма объектов первого класса окрашена в красный цвет, гистограмма, построенная для объектов второго класса, – в синий цвет.

Видно, что для всех параметров оба класса объектов всегда распределены практически на одном и том же интервале значений. То же самое справедливо и в отношении всех остальных параметров (гистограммы мы не приводим). Следовательно, необходимо строить новые параметры, более информативные с точки зрения разделения двух классов объектов. Ясно, что новые параметры могут быть только комбинациями тех или иных функций от старых – исходных – параметров. Если ограничиться отысканием наилучших *линейных* комбинаций исходных параметров, необходимо воспользоваться методом главных компонент [1–3].




Рис. 1. Гистограммы распределений объектов вдоль первых исходных параметров: красный цвет – объекты 1-го класса, синий цвет – 2-го класса

Метод главных компонент

Метод главных компонент позволяет формальными методами строить правильные линейные комбинации исходных параметров – их называют главными компонентами. Эти главные компоненты обладают целым рядом полезных свойств.

Во-первых, дисперсия распределения объектов вдоль главной компоненты может на 1–2 порядка превосходить дисперсию распределения объектов вдоль исходных параметров, равную – напомним, 1 – см. (2). Это, несомненно, очень полезное свойство: чем больше дисперсия распределения объектов, тем более информативной является построенная характеристика. Тем больше шансов, что с помощью этой характеристики удастся «расташить» по разным интервалам объекты, принадлежащие разным классам. Во-вторых, все главные компоненты являются некоррелированными: скалярное произведение любой пары главных компонент равно 0.

Прежде чем переходить к изложению результатов, заметим, что метод главных компонент является одним из вариантов *факторного анализа* – идеологии обработки больших информационных массивов, направленной

на конструирование из исходных параметров новых характеристик, являющихся выражением глубинных свойств эмпирического материала, возможно, даже таких свойств, которые в принципе не поддаются измерению. Эти новые характеристики называют *факторами*, чтобы отличать их от исходных параметров. Главные компоненты как раз и доставляют пример подобных факторов. В дальнейшем мы будем равно пользоваться обоими терминами: главные компоненты = факторы.

На верхней панели рис. 2 вдоль оси абсцисс отложены номера главных компонент (факторов), а по оси ординат – дисперсия распределения вдоль них объектов. Дисперсии первых четырех факторов приблизительно равны 12, 7, 6 и 4, что в сумме покрывает около 66% суммарной дисперсии эмпирического материала. В соответствии с общепринятым протоколом мы можем ограничиться первыми четырьмя главными компонентами и анализировать распределение наших объектов в сконструированном четырехмерном пространстве вместо того, чтобы анализировать их распределение в исходном 44-мерном пространстве.

На нижней панели рис. 2 для каждого значения k показано, сколько процентов общей дисперсии эмпирического материала учитывается первыми k главными компонентами.




Рис. 2. Верхняя панель: дисперсии распределений объектов вдоль всех 44 главных компонент. Нижняя панель: суммарная дисперсия, приходящаяся на первые k главных компонент (%)

Распределение объектов вдоль главных компонент (факторов)

На рис. 3 показаны распределения всех 72 объектов вдоль построенных выше четырех главных компонент. Нельзя сказать, что удалось получить хотя бы одну характеристику, значения которой для объектов из двух разных классов уверенно разделялись бы. На всех панелях мы видим, что интервалы, на которых сосредоточены гистограммы распределения объектов их разных классов, существенно перекрываются. Только распределение вдоль третьего фактора (нижняя левая панель) позволяет надеяться на некое подобие разделения объектов на два класса: значительная часть объектов первого класса сосредоточена здесь на правом конце интервала, а центр распределения объектов второго класса смещен существенно левее. Мы увидим ниже, что с помощью третьего фактора удастся растянуть значительную часть объектов из разных классов.

Некое подобие аналогичного разделения объектов наблюдается и для второго фактора (правая верхняя панель), но в более смазанном виде. Наиболее эффективным в этом смысле оказывается именно третий фактор. Неожиданным образом самый информативный – первый – фактор не дает почти ничего для разделения объектов из двух классов.




Рис. 3. Гистограммы распределения объектов вдоль первых четырех факторов

$\mathbf{f}^{(j)}, j=1, 2, 3, 4$. Верхние панели: левая – $\mathbf{f}^{(1)}$, правая – $\mathbf{f}^{(2)}$, нижние панели:

левая – $\mathbf{f}^{(3)}$, правая – $\mathbf{f}^{(4)}$

Распределение объектов на плоскости

Поскольку распределение объектов вдоль факторов не позволяет добиться сколько-нибудь удовлетворительного разделения объектов из разных классов, необходимо перейти к анализу их распределения на плоскостях, образованных построенными факторами.

На рис. 4 показаны распределения 72 объектов в 6 плоскостях, осями которых являются комбинации четырех факторов $\mathbf{f}^{(j)}$.




Рис. 4. Распределение объектов в плоскостях, координатными осями которых служат пары факторов $\langle \mathbf{f}^{(i)}, \mathbf{f}^{(j)} \rangle$

Мы стремимся отыскать плоскость, в которой можно было бы простой разграничительной линией, например, прямой, надежно разделить объекты из двух классов. Либо же добиться хотя бы квазиразделения объектов: отделить прямой линией *значительную* часть объектов из одного класса от *заметного* количества объектов из другого класса.

С этой точки зрения очевидно, что наиболее продуктивными являются плоскости $\langle \mathbf{f}^{(2)}, \mathbf{f}^{(3)} \rangle$ и $\langle \mathbf{f}^{(3)}, \mathbf{f}^{(1)} \rangle$ – средняя и соответственно крайняя правая панели верхнего ряда на рис. 4. В первом случае квазиразделение

доставляется прямой линией, почти параллельной оси абсцисс, и отделяющей значительную часть объектов одного класса от объектов другого класса (прямая не показана). Для второй плоскости аналогичное квазиразделение получается с помощью прямой линии с отрицательным наклоном, смещенной к правому концу оси абсцисс. И эта прямая (не показана) отделяет большую часть объектов из одного класса от большей части другого класса.

В то же время крайняя левая плоскость верхнего ряда с осями $\langle \mathbf{f}^{(1)}, \mathbf{f}^{(2)} \rangle$ гораздо менее продуктивна. Похоже, что именно наличие среди осей координат фактора $\mathbf{f}^{(3)}$ обеспечивает нам, по крайней мере, квазиразделение объектов. И уж совсем никак не помогает разделять объекты фактор $\mathbf{f}^{(4)}$ – все три панели нижнего ряда демонстрируют, что распределение объектов по оси ординат сильно сжато.

Таким образом, для дальнейшей работы наиболее информативными являются первые три фактора, а четвертый фактор следует отбросить.

Дальнейшее обсуждение и выводы

Один из вариантов следующего этапа обработки материала может состоять в том, чтобы заняться анализом распределения объектов в трехмерном пространстве, осями координат которого являются три отобранных на предыдущем этапе фактора: человеческой интуиции хватает для анализа распределений в трехмерном пространстве.

Мы имеем в виду эту возможность, но, кроме того, обратили внимание на следующее обстоятельство. В случае не слишком изощренных распределений объектов в многомерном пространстве необходимым условием их разделимости является надежное разделение центров тяжести двух классов (их еще называют *центроидами*). Построим, например, в исходном признаковом пространстве центроид объектов первого класса

$$\mathbf{S}_1 = \sum_{i=1}^{37} \mathbf{x}_i / 37 \text{ и центроид объектов второго класса } \mathbf{S}_2 = \sum_{i=38}^{72} \mathbf{x}_i / 35.$$

Разность $\mathbf{S}_{12} = \mathbf{S}_2 - \mathbf{S}_1$ задает выделенное направление в исходном m -мерном пространстве. Действительно, необходимым условием того, чтобы два класса объектов можно было разделить гиперплоскостью, является требование того, чтобы центроиды классов находились по разные стороны разделяющей гиперплоскости, проходящей через середину вектора $\mathbf{S}_{12}$. На этом соображении удастся создать несколько вычислительных приемов, которые позволяют существенно улучшить качество разделения объектов. Мы надеемся вскоре завершить работы в этом направлении.

Скажем несколько слов о содержательной интерпретации построенных факторов, которая является привлекательным бонусом метода главных компонент. Факторы (главные компоненты) получают с помощью формальных процедур как взвешенные линейные комбинации исходных параметров. Среди весов, приписанных параметрам, многие будут иметь очень маленькие значения – порядка $10^{-3} - 10^{-5}$. А другие веса по порядку величины будут равны $10^{-1} - 10^{-2}$. Ясно, что именно этими последними параметрами определяется «лицо» построенного фактора: содержательная интерпретация фактора определяется несколькими параметрами, которые входят в линейную комбинацию с большими весами.

Если удастся провести содержательную интерпретацию построенных факторов, появляется возможность создавать феноменологическую теорию исследуемого вопроса в *содержательных* терминах, что значительно расширяет возможности исследователя (по сравнению с получением одной только удовлетворительной классификации объектов).

Необходимо отметить, что слабый пункт метода главных компонент состоит в том, что в формировании факторов участвуют все параметры – в некоторых очевидных ситуациях это может приводить к неприятным последствиям для конструкции факторов. Альтернативу предоставляет *экстремальная группировка параметров* [1], [4] – вариант метода главных компонент, в котором сначала все множество параметров разбивается на группы сильно коррелирующих. Затем для каждой такой группы строится один фактор, например среднее по группе векторов-параметров либо же первая главная компонента. Этот подход хорошо зарекомендовал себя в прошлом [1], [5], [6].

Необъятное море вариантов нелинейного метода главных компонент стоит изучать по материалам [7].

В целом описанная задача и подходы к ее решению представляются нам перспективными.

Во время работы мы пользовались помощью и советами своих коллег: Я.М. Карандашева, В.Б. Котова, Б.В. Крыжановского и О.Ю. Ребровой. Ответственность за изложение лежит на авторе доклада.

Список литературы

1. Браверман Э., Мучник И. Структурные методы обработки эмпирических данных. Москва : Наука, 1986.
2. Харман Г. Современный факторный анализ. Москва : Статистика, 1972.

3. Лоули Д., Максвелл А. Факторный анализ как статистический метод. Москва : Мир, 1973.
4. Браверман Э.М. Метод экстремальной группировки параметров и задача выделения существенных факторов // Автоматика и телемеханика. 1970. № 1. С. 123-132.
5. Лумельский В. Я. Группировка параметров на основе квадратной матрицы связи // Автоматика и телемеханика. 1970. № 1. С. 133–143.
6. Тужилина Е. Использование метода понижения размерности в медицинских исследованиях. 2017, препринт.
7. Горбань А.Н. и др. Нелинейный метод главных компонент. <http://pca.narod.ru/>.

А.В. ЛОБАНОВ, Г.Г. ЛАЗАРЕВА

Российский университет дружбы народов, Москва
alexey-vladimirovich-lobanov@yandex.ru

ПЕРВИЧНАЯ ПОДГОТОВКА ДАННЫХ ДЛЯ АНАЛИЗА СНИМКОВ МСКТ ГОЛОВНОГО МОЗГА ДЛЯ ЗАДАЧИ ПОИСКА ПЕРВИЧНЫХ ПРИЗНАКОВ ИНСУЛЬТА ГОЛОВНОГО МОЗГА

В рамках задачи поиска областей с первичными признаками инсульта головного мозга имеется необходимость в начальной фильтрации данных снимков мультиспиральной компьютерной томографии (МСКТ) головного мозга для контрастного выделения потенциальных аномальных областей. Представлен алгоритм предподготовки данных в рамках исследуемой задачи.

Ключевые слова: *фильтрация изображения, ишемический инсульт головного мозга.*

Введение

Инсульт головного мозга – серьезное заболевание, требующее оперативных процедур реагирования. Достоверным способом его определения является визуальный анализ снимков головного мозга специалистом. Безусловно существуют способы улучшить репрезентативность снимков, например, введением контрастного вещества [1], однако это требует длительного времени, увеличивает риски для пациентов, экономически не выгодно.

Важно понимать, что на начальном этапе протекания болезни его проявления могут оказаться слабыми, а значит, качество визуального анализа зависит лишь от опыта специалиста. Это приводит к ошибкам интерпретации, что в худшем случае приводит к непоправимым последствиям или смерти [2, 3]. Поэтому возникает потребность в построении инструмента, позволяющего помогать специалисту определять потенциальные аномальные области для улучшения качества анализа снимков, чтобы впоследствии верно ставить диагноз.

В силу особенностей проявлений заболевания применение классических способов определения аномальных зон на основе нейронных сетей [4], как, например, в задачах определения новообразований [5, 6], является затруднительным. Это обусловлено рядом причин: зашумленность снимков, недостаточная плотность аномальных областей на пространстве

снимка. Более того, эти области обычно отличаются всего на 1–2 пункта яркости от значений яркости нормальных тканей. Ещё одной проблемой является закрытость и запрет на распространение медицинских данных, что заставляет применять для увеличения размеров обучающих данных специфичные методики [7]. Таким образом, применение нейросетевого подхода не может быть реализовано с гарантией достоверности результатов. Поэтому на этом этапе работы создание инструментов для выделения аномальных участков надежными методами фильтрации является актуальным и востребованным на практике.

Постановка задачи

Нами рассматривается предварительный этап задачи по поиску первичных признаков ишемии головного мозга. В рамках этого этапа необходимо создать алгоритм преобразования изначальных данных, являющихся набором двумерных массивов, хранящих информацию результатов снимков МСКТ головного мозга, для последующей детекции аномальных участков.

Оценка и преобразование исходных данных

Снимок МСКТ головного мозга представляет собой двумерный массив чисел, каждая ячейка которой является результатом записи значения ослабления рентгеновского излучения на тканях разной плотности.



Рис. 1. Отображение массива значений данных снимка МСКТ: (а) в диапазоне шифровки стандартного пикселя, (б) после преобразования в диапазоне, соответствующей тканям головного мозга

В нашем исследовании рассматриваются снимки стандартного разрешения МСКТ аппаратов 512 на 512 пикселей. Значения массива варьируются от 0 до более чем 3000 единиц.

Стандартным способом визуализации массива чисел является транспонирование её значений на диапазон 0–255 – стандарт кодировки пикселя. В таком представлении (рис. 1а) появляются некоторые несущественные объекты (например, подушка под голову), а существенные наоборот становятся не интерпретируемыми. Так, область тканей головного мозга сливается практически в единое серое пространство, вследствие чего различия в значениях в интересующих областях будут мизерными. Поэтому первичной задачей алгоритма является приведение данных к репрезентативному виду.

Для улучшения интерпретируемости снимка МСКТ рассмотрен график усредненных частот значений на большом наборе данных (рис. 2а). Снимок представляет собой двумерный массив данных с элементами x , принимающими целочисленные значения в диапазоне от нуля до 3000. На графике по оси абсцисс отложены значения элементов этого массива, по оси ординат – количество элементов, принимающих это значение, в массиве. Необходимо отметить, что график является результатом осреднения распределений частот, полученных для сотен снимков МСКТ. Осреднение правомерно, так как полученные на одном аппарате МСКТ снимки различных пациентов имеют схожий вид распределения частот. Проанализировав полученное осредненное распределение, получены следующие выводы:

- К нулевым значениям относится пространство темного цвета, в котором аппарат не имеет отклика от твердых структур.
- К около нулевым значениям относятся значения пикселей, описывающие структуры со слабым откликом (мягкая подушка под голову, хрящевые структуры головы, глазные яблоки). Они кодируются значениями до 500, и это отражено на частотном графике первым всплеском.
- Ко второму выплеску (заштрихованный диапазон) на графике относятся значения пикселей из области $[b_1, b_2]$, соответствующей тканям головного мозга.
- К сверхвысоким значениям (свыше 1104) относятся области, кодирующие твердые структуры несущественные для анализа (рамка аппарата, черепная коробка головного мозга).

На данном этапе задача состоит в построении такого преобразования значений, которое бы увеличило репрезентацию значений пикселей области головного мозга.




Рис. 2. График средних частот встречаемости W значений x массива данных снимка МСКТ (а), график функции фильтрации (2) при $a = 128$ (б)

Основываясь на данных частотного графика, составленного на показательном наборе исходных изображений, была составлена формула преобразования значений пикселей изначального массива в диапазоне, соответствующей тканям головного мозга:

$$f(x) = \begin{cases} 0, & x \leq b_1, \\ \text{round}(a_1(x - b_1 + 1) + a_2), & b_1 < x \leq b_2, \\ 255, & x > b_2, \end{cases} \quad (1)$$

где x – значение элемента массива, $b_1=1025$, $b_2=1104$ – границы диапазона изменяемых значений, $a_1=3$, $a_2=5$ – параметры. В результате такого преобразования существенно улучшается репрезентация исходных данных (рис. 1). Снимок передает структуру головного мозга достаточно подробно, близко к результатам автоматической обработки аппарата МСКЦ, которые изучают медики в процессе диагностики (рис. 1б).

Фильтрация изображения

Основная задача выделения области с первичными признаками инсульта решается в процессе фильтрации, который состоит из нескольких этапов.

Отбрасывание артефактов. Имеется необходимость избавиться от отображения анатомических участков головы, несущественных для решения поставленной задачи, и побочных элементов, таких, как рамка аппарата, которая поддерживает голову. Так как рамка сделана из очень плотного материала, то она будет иметь самый яркий белый цвет изображения и кодироваться самым большим значением. Кость черепной коробки тоже существенно более плотная, чем ткань головного мозга. Область коры головного мозга не отображается такими яркими пикселями, поэтому зна-

чения пикселей вне их диапазона можно заменить нулем. В результате получено изображение без ненужных артефактов (рис. 3 б), которое было получено модификацией формулы (1). Отбрасывание артефактов осуществляется путем выделения значений, соответствующих только нужному диапазону мягких тканей:

$$f(x) = \begin{cases} 0, & x \leq b_1, \\ \text{round}(a_1(x - b_1 + 1) + a_2), & b_1 \leq x \leq b_2, \\ 0, & x \geq b_2, \end{cases} \quad (2)$$



Рис 3. Отбрасывание ярких артефактов: (а) – отображение после применения формулы преобразования (1), (б) – отображение после применения модифицированной формулы (2)

Размытие. Полученное изображение имеет большую зернистость (зашумленность). Чтобы избавиться от зашумленности, существует большое количество методик разной степени сложности: размытие по Гауссу, размытие в движении и т.д. Однако проблематика ставит перед нами цель – сохранить как можно точнее исходную картину топографии головного мозга, так как мелкие артефакты могут оказаться презентацией первичных признаков инсульта вместе с большой скоростью выполнения методики. Поэтому было выбрано два способа фильтрации, подходящих для решения текущей задачи, согласно [8].

Первый вариант фильтрации построен по следующему правилу: двумерный массив значений разбивается на непересекающиеся квадраты размерности 2×2 , каждое значение в квадрате заменяется на один из вариантов – минимальное (рис. 4а), усредненное (рис. 4б), максимальное значение (рис. 4в).




Рис. 4. Первый вариант фильтра размытия для одного среза МСКТ: (а) приведение к минимальному значению, (б) приведение к усредненному значению, (в) приведение к максимальному значению

Таким образом, приведение каждого квадрата к минимальному значению усиливает на визуальном уровне вклад темных пикселей (рис. 4а).

Другой выбранный способ для устранения зернистости изображения в рамках нашей задачи – медианное размытие (рис. 5а). Суть медианного размытия заключается в следующем: для каждого пикселя исходного изображения рассматриваются значения соседних пикселей, среди которых выбирается медианное, которое в результате и присваивается как результат применения медианного размытия.




Рис. 5. Сравнение фильтров: (а) оригинальное изображение, (б) применение медианной фильтрации, (в) применение первого варианта фильтрации для одного среза МСКТ

В результате медианная фильтрация была выбрана как самый лучший вариант фильтрации в рамках данной задачи. Этот вид фильтрации не искажает изображение (в отличие от гауссова размытия), не ухудшает качество изображения (в отличие от первого варианта фильтрации) и в то же время хорошо сглаживает зернистость.

Усиление темных областей. Проявление первичных признаков ишемии заключается в потемнении области поражения всего на 1–2 пункта яркости. Поэтому усиление затемнения области поражения является приоритетной задачей. Для этого предлагается использовать функцию сигмоида:

$$g(x) = \begin{cases} \frac{255}{1 + \exp(-2cx/255 - c)}, & x \leq a, \\ x, & x \geq a, \end{cases} \quad (3)$$

где $a \in [0, 255]$ – граница области коррекции, $c = 6$ – параметр. Функция оставляет пиксели со значениями выше порогового значения a неизменными, при этом значительно занижая значения остальных пикселей. В результате при увеличении параметра a происходит усиление темных областей, что видно из (рис. 2б). В виде (3) функция сигмоида позволяет усиливать слабые значения и не меняет сильные, что видно из рис. 6.

Для определенности пороговое значение было выбрано как $a = 128$. Такой выбор порогового параметра обусловлен тем, что полученные изображения имеют яркую выраженность в участках головного мозга с потенциальными признаками ишемического инсульта и в то же время сохраняют анатомическую картину головного мозга для нормальной интерпретации специалистом. При сопоставлении полученных изображений с исходными (рис. 7) становится очевидным визуальное выделение тех участков, в которых специалист усматривает первичные признаки инсульта головного мозга. Эта процедура позволяет переподготавливать данные из исходных файлов в интерпретируемый вид для дальнейшей работы.

В дальнейшем предполагается проводить разделение областей мозга, кровоснабжаемых средней мозговой артерией на десять отдельных участков, в соответствии со шкалой ASPECTS.




Рис. 6. Пример применения функции сигмоида (3) при различных параметрах α . Белым цветом выделены области с первичными признаками ишемического инсульта головного мозга отмеченные специалистом




Рис. 7. Примеры результатов использования предложенного алгоритма фильтрации

Сегментация областей предполагаемого ишемического поражения будет выполняться с использованием методов *dbscan* и *optics*. Объемная картина поражения будет восстанавливаться, как в работе [9]. Выполненные первичные преобразования данных являются подготовительным этапом для сегментации.

Выводы

В статье представлен построенный алгоритм фильтрации данных МСКТ головного мозга, который сможет облегчить аналитику снимков в рамках шкалы ASPECTS [10]. Этот алгоритм визуально подчеркивает области, в которых определяются ранние признаки ишемических изменений. Предложен специализированный фильтр для усиления значений пикселей в области с потенциальными изменениями ишемического свойства. Сравнение исходных и преобразованных изображений показывает получение выделения тех участков, в которых специалист усматривает первичные признаки инсульта головного мозга. Этот метод может быть применен к целому классу задач, связанных с поиском ишемии или на различных этапах развития заболевания и определения новообразований головного мозга или других аномалий.

Список литературы

1. Анисимов Н.В., Батова С.С., Пирогов Ю.А. Магнитно-резонансная томография: управление контрастом и междисциплинарные приложения. Москва : МАКС Пресс, 2013. С. 91–96.
2. Kim-Tenser M. [et al.]. CT perfusion core and ASPECT score prediction of outcomes in DEFUSE 3 // International Journal of stroke: official Journal of the International Stroke Society. 2021. V. 16, N 3. P. 288-294.
3. Van Horn N. [et al.]. Predictors of poor clinical outcome despite complete reperfusion in acute ischemic stroke patients // Journal of neurointerventional surgery. 2021. V. 13, N 1. P. 14–18.
4. Волчек Ю.А., Шишко О.Н., Спиридонова О.С., Мохорт Т.В. Положение модели искусственной нейронной сети в медицинских экспертных системах // *Juvenis scientia*. 2017. N 9.
5. Ramaswamy Reddy A., Prasad E.V., Reddy L.S.S. Comparative analysis of brain tumor detection using different segmentation techniques // International Journal of Computer Applications. 2013. V. 82. N 14. P. 0975–8887.
6. Das S., Siddiqui N.N., Kriti N., Tamang, S.P. Detection and area calculation of brain tumour from MRI images using MATLAB // International Journal. 2017. V. 4. N 1. P. 35.
7. Billot B. [et al.]. SynthSeg: Domain Randomisation for Segmentation of Brain Scans of any Contrast and Resolution // arXiv: 2107.09559. 2021.

8. Kumar A., Sodhi S.S. Comparative Analysis of Gaussian Filter, Median Filter and Denoise Autoencoder // IEEE 2020 7th International Conference on Computing for Sustainable Global Development (INDIACom). 2020. P. 45–51.
9. Danilov A., Ivanov Yu., Pryamonosov R., Vassilevski Yu. Methods of graph network reconstruction in personalized medicine // Int. J. Numer. Meth. Biomed. Engng. 2015.
10. Pexman J.H. [et al.]. Use of the Alberta Stroke Program Early CT Score (ASPECTS) for assessing CT scans in patients with acute stroke // AJNR. American Journal of neuroradiology. 2001. V. 22, N 8. P. 1534–1542.

**М.В. МАКАРОВ, И.А. СЕМЕНОВ, А.А. ДЕМИДОВ,
Н.С. ТРАНИНА**

Муромский институт Владимирского государственного университета
им. Александра Григорьевича и Николая Григорьевича Столетовых
nauka-murom@yandex.ru

ИССЛЕДОВАНИЕ НОВОГО ТИПА ЭВРИСТИЧЕСКИХ РЕШЕНИЙ ДЛЯ АДАПТИВНОГО УПРАВЛЕНИЯ МОБИЛЬНЫМ РОБОТОМ В ДИНАМИЧЕСКОЙ СРЕДЕ*

В статье представлены теоретические сведения, раскрывающие сущность нового типа эвристических решений, синтезируемых внутри компонентов системы управления мобильным роботом. Разработана и реализована методология экспериментального исследования, направленного на обоснование осуществимости одного из аспектов синтеза подобных решений. Выявлено, что реализация данного аспекта возможна в рамках нейросетевой архитектуры и приводит к повышению адаптационных способностей робота в условиях динамической среды существования.

Ключевые слова: *мобильные роботы, искусственные нейронные сети, адаптивное управление, принятие решения, эвристика.*

Введение

Расширение области применения мобильных роботов требует совершенствования данных устройств с целью реализации внутри них дополнительных функций. Например, помещение подобных систем в динамическую среду значительно усложняет процесс управления, где появляется множество трудноформализуемых задач принятия решения, включающих в себя результаты прогнозирования отдельных аспектов среды существования, планирования собственных действий и оценки последствий принимаемых решений, а также абстрактного и нечёткого описания внешних объектов [1–6]. Все это будет способствовать исполнению системой управления роботом рациональных поведенческих функций, основанных на квазикогнитивных принципах принятия решений, возможных благодаря использованию методов интеллектуальной обработки информации.

* Исследование выполнено за счет гранта Российского научного фонда № 22-21-20111, <https://rscf.ru/project/22-21-20111/>.

Получившие распространение методы интеллектуальной обработки информации [7–11] основаны на регрессии множественного прецедентного опыта и по-прежнему существуют в парадигме алгоритмического преобразования данных. Это ограничивает реализацию одновременной структурной и параметрической пластичности компонентов обработки информации, что, в свою очередь, лишает систему возможности накопления и использования квазикогнитивного опыта, позволяющего оперировать суждениями об изменении обстоятельств, важных для описания текущей ситуации. Этот факт исключает точное перестроение модели управления в реальном режиме времени и делает невозможным исполнение системой управления в полной мере поведенческих функций адекватных условиям высокой вероятности изменения функциональных зависимостей, являющихся основой для работы робота в рамках своих компетенций. В результате возникает необходимость принятия решений в условиях недостоверности информации, её неполноты или содержащихся в ней противоречий, что существующими методами труднореализуемо или невозможно в принципе.

Исходя из этого, очевидна потребность в проведении фундаментальных исследований, результаты которых могут стать основой для перехода к управлению, включающему в себя синтез сложных эвристических решений и, как следствие, автономную адаптацию поведения робота под изменение внешних условий динамической среды его существования.

Преодоление обозначенной проблемы связано с решением научных задач, одна из которых и определяет теоретическую и практическую значимость описываемого в данной работе исследования. Оно направлено на проверку концепции, предполагающей возможность воссоздания внутреннего субстрата системы для формирования квазикогнитивного базиса при синтезе эвристических решений, что является одним из ключевых аспектов устранения представленных выше недостатков современных методов интеллектуальной обработки информации. Кроме того, важным является проведение проверки состоятельности использования нейросетевой вычислительной архитектуры в качестве базовой инструментальной платформы протекания предлагаемых процессов.

Предполагается, что решение заявленной задачи внесет существенный вклад в дальнейшее развитие прикладного проблемно-ориентированного искусственного интеллекта и позволит создавать мобильные роботы с адаптивным управлением, которые будут обладать максимальными техническими характеристиками при функционировании в условиях динамической среды существования.

Теоретические аспекты исследования

Современное представление об эвристики не является полностью релевантным к рассматриваемой предметной области. Применение эвристических моделей в процессе принятия решения внутри мобильных роботов можно встретить в ряде исследований [12-14]. Но, как правило, эвристические методы воспринимаются исключительно в качестве стохастических подходов, направленных на ускорение сходимости решения сложной вычислительной задачи, для которой нерационально использовать детерминированные алгоритмические методы. Представим новый взгляд на синтез эвристического решения, осуществляемый в целях автономной регуляризации поведения робота при изменении условий внешней среды существования.

В первую очередь определим, что следует понимать под эвристическим решением нового типа. Ключевым свойством этого решения является несводимость процесса его синтеза к установлению прямой функциональной зависимости между выходным результатом и входной сенсорной информацией. Предполагается, что принимаемое решение связано и имеет смысл только в совокупности с качественным описанием процесса его синтеза. Тогда появляется необходимость в информационном субстрате для извлечения альтернативного видения и оценки ситуации принятия решения с точки зрения некой стратегии. В основе подобного субстрата должны лежать квазикогнитивные принципы обработки информации, подразумевающие участие внутренних факторов для формирования дополнительного признакового пространства в системе на этапе синтеза решения. А для существования дополнительного класса информации требуется иная форма её представления в системе, а сама система должна быть выражена двойственностью обрабатываемой информации.

Возникает вопрос, что такое двойственность обрабатываемой информации и как она формирует смысл процесса её обработки? Технологии интеллектуальной обработки информации допускают вариацию представлений об этом феномене. Договоримся, что отправной точкой в восприятии возникновения этого явления в технических системах обработки информации будем считать помещение результата преобразования данных в контекст. В отличие от других вариантов употребления понятия контекст, например, фигурирующего в источнике [15], следует уточнить, что в данном случае контекст – это не сигнификат алфавитного символа в знаковой системе, а способ внесения смысла через структурную и параметрическую настройку системы.

Для реализации двойственности требуется сформировать собственную

семиотическую среду в системе и сохранить образность представления о внешней среде, что позволит достигнуть заявленных целей. С точки зрения естественного языка семиотика подразделяется на синтаксис, семантику и прагматику и для представленного исследования интересны первые два элемента знаковой системы. Классические методы обработки информации используют ресурсы только синтаксиса и предполагают весьма примитивное участие смысловой составляющей в преобразовании данных. Это справедливо, в том числе и для интеллектуальных средств машинного обучения. Другими словами, процесс обработки информации основывается на кодировании и статистических связях между кодируемыми элементами. Примерами попытки перехода к эффекту двойственности можно считать использование архитектуры рекуррентных нейронных сетей [16], где присутствует разграничение потоков информации, один из которых устанавливает статистическую зависимость между отдельными единицами синтаксической структуры обрабатываемых данных. Однако дублирование информационных потоков, использующих аналогичные принципы, не способны решить проблему. Это приведет исключительно к росту потребностей в вычислительных ресурсах и не создаст неразрывную общность между формой существования информации и её смыслом.

Методология экспериментального исследования

В качестве объекта экспериментального исследования выступала компьютерная модель абстрактной системы, имитирующей поведение разведывательного мобильного робота в динамической среде. Осуществлялась автономная навигация данной системы, способствующая её перемещению по оптимальной с точки зрения объема получаемой информации траектории и при учёте ограничений, накладываемых динамическими и статическими объектами в оперативном поле пространства. На рис. 1 можно увидеть графическое представление видения системой пространства вокруг него, полученное в результате решения задачи одновременной локализации и картографирования в процессе нескольких циклов перемещения системы. В частности, из него мы можем видеть, как возникающие подвижные объекты будут дестабилизировать построение модели среды, что повлияет на выбор оптимальных траекторий и приведет к снижению эффективности решения прикладных задач роботом. Результаты этих воздействий отражены на карте различными типами нечёткости границ статических объектов и появлением движущихся объектов, распознанных и ошибочно считааемых статическими препятствиями.

Программная реализация объекта исследования подразумевает, что

поведение системы (оперативную коррекцию выбранной траектории на основе модели среды) определяет компонент принятия решения. Он принимает на вход вектор данных, содержащий информацию об оперативной ситуации, полученной на основе процедуры локализации и картографирования (сетку занятости), а также дополнительных оценок среды (фильтрация динамических объектов).




Рис. 1. Графическое представление виртуального пространства динамической среды существования объекта исследования

Результат работы данного компонента – это инструкция для предпочтительного действия, существующая в виде вектора данных, указывающего одну из возможных активностей для текущего шага: движение вперед согласно принятой траектории, отклонение от принятой траектории вправо, отклонение от принятой траектории влево, остановка и ожидание, разворот и т.п.

Базовой вычислительной архитектурой компонента принятия решения, определяющего каждый шаг системы – это многоступенчатая нейросетевая конфигурация, включающая в себя свёрточные слои для построения сетки занятости и обработки одометрии, а также ячейки многослойных искусственных нейронных сетей для обобщения информации. В результате обучения на 20 000 проходах удалось получить механизм, способный с высокой степенью точности аппроксимировать заданную функциональную зависимость. Обучение проводилось до получения максимального качества преобразования информации, выражавшееся вероятностным индикатором оптимальных принятых решений на 500 тестовых шагах.

Описанная ранее теоретическая концепция эвристического решения нового типа предполагает организацию внутреннего информационного субстрата для его синтеза, то есть помещения решения в контекст поведения системы. Таким образом, мы должны избавиться от абсолютной зависимости синтезируемого решения от входных сенсорных данных и учитывать условия среды существования системы. Как было сказано ранее, ожидаемая структурная и параметрическая вариативность обработчика информации должна производиться за счет двойственности.

Эффект двойственности был инкорпорирован в объект исследования с помощью особой модификации полносвязной нейросетевой ячейки и специальной функции активации нейронов. На рис. 2 представлена упрощенная структурно-функциональная схема такой ячейки, результирующей синтез эвристического решения нового типа. На выходе данного слоя ожидается нечёткое высказывание, интерпретируемое любой подходящей для этого системой нечеткого вывода. В данном исследовании в качестве поддержки нечеткого вывода использовался метод соотношения площадей (MAR-ANFIS) [17]. Под высказыванием подразумевается выбранный вариант следующего шага системы с обоснованием в виде одной из конечного множества стратегий: обход препятствия слева, обход препятствия справа, ожидание и разведка, возврат и т.п.




Рис. 2. Структурно-функциональная схема предлагаемой для синтеза эвристического решения модификации нейросетевой архитектуры

Из рис. 2 можно увидеть, что описываемая ячейка предполагает, как минимум, два вычислительных слоя. Первый слой получает используемую для принятия решения входную информацию, но не в чистом виде, а на основе производимых матрицей целеполагания преобразований. Результатом активации первого слоя является не вектор скалярных значений степени активации каждого нейрона, а множество функций. Эти функции будут использоваться в качестве активационных для нейронов последующего слоя. Аналогичная количественная форма входной информации подается и на второй вычислительный слой, где происходит другой этап преобразования образной информации для формирования нового пространства признаков. Такая архитектура ячейки позволит воссоздать структурную вариативность и способствует устранению строгой зависимости синтезируемого решения от входных сенсорных данных.

Отличительной особенностью процесса активации будет тот факт, что при использовании привычных базовых нелинейных функций предполагается, что значение выхода нейрона является количественным эквивалентом степени его участия в общем результате решения задачи. Такой подход позволяет описывать степень участия в количественном измерении, но не в качественном. Для демонстрации качественных характеристик процесса обработки информации активацией нейрона должно быть не единичное скалярное значение, а функция. Это способствует формированию внутреннего состояния системы, которое включает в себя отражение внешних условий решения задачи. Такое состояние оказывает действие (способ описания процесса) на активацию, что в свою очередь и определяет контекст синтезируемых решений.

Результаты экспериментального исследования и их обсуждение

Исследование состояло из группы экспериментов. В каждом случае разработанная модель компонента принятия решения в составе объекта исследования симулировала функционирование этой системы в виртуальных пространствах различных конфигураций. Одним из примеров используемого пространства, как оно представлено в системе, может послужить иллюстрация на рис. 3. В рамках подобных пространств осуществлялось четыре типа динамических дестабилизирующих воздействий: присутствие равномерно движущихся объектов, присутствие появляющихся и исчезающих объектов, присутствие движущихся объектов с ускорением, присутствие искривляющих пространство объектов. Каждое такое воздействие изменяло общее правило преобразования информации и принятия решения. Это связано с тем, что менялась внутренняя поведенческая мо-

тивация системы. Например, идентификация динамического объекта как статическое препятствие стимулирует выработку обходных путей вместо ожидания и получения новой информации.



Рис. 3. Графическое представление используемого виртуального пространства, полученное в результате проведения одного из экспериментов

Статистика по всем трем проведенным экспериментам представлена в табл. 1, где количественные характеристики описывают наиболее важные с точки зрения задач работы аспекты функционирования (эмуляции поведения) объекта исследования. Для наглядности полученные результаты содержат аналогичные характеристики, но полученные в идентичных условиях при использовании стандартного на сегодняшний день алгоритмического подхода.

Таблица 1

Статистика проведенных экспериментов

Номер эксперимента, №		1	2	3
Время решения задачи, условные секунды	Алгоритмич. подход	221	244	319
	Эвристич. подход	237	263	336
Общее количество моментов синтеза решений, шт.	Алгоритмич. подход	1002	1060	1220
	Эвристич. подход	1019	1104	1311
Отклонение от оптимальной траектории, %	Алгоритмич. подход	0,23	0,51	2,3
	Эвристич. подход	0,02	0,03	0,05
Доля несовпадающих решений, %	Алгоритмич. подход	-	-	-
	Эвристич. подход	11	18	36

Критерием, интерпретирующим результаты проведенного исследования, можно считать установление факта отсутствия полной зависимости от изменения выходного вектора, интерпретирующего синтезированное решение. Из представленных в табл. 1 результатов можно увидеть, что присутствовала существенная доля изменений решений, вызванных внесенными в процесс обработки информации изменениями.

Выводы

Полученные результаты позволяют сделать вывод, что существует возможность формирования квазикогнитивных механизмов обработки информации, которые могли бы использоваться в качестве субстрата для синтеза нового типа эвристических решений внутри системы управления мобильным роботом, функционирующим в динамической среде. В рассматриваемом случае внесение структурных изменений в компонент принятия решения привело к возникновению отклика в адаптационных способностях объекта исследования при дестабилизации внешних условий. Можно сделать вывод, что подобный информационный субстрат для нового способа описания внешней среды привел к расширению поведенческого потенциала мобильного робота.

Однако исследование предлагало ряд допущений. Во-первых, следует принять тот факт, что в системе реализована дополнительная абстракция среды существования системы, позволяющая формировать контекст её поведения директивно, а не как автономная процедура, возникающая внутри системы. Во-вторых, мы допускаем, что уже организована функция автономного целеполагания, формирующая локальные потребности системы. Реализуемость в полной мере и с максимальной эффективностью адаптивного управления в рамках предложенной теоретической концепции синтеза эвристических решений возможна только при соблюдении этих условий. Дальнейшие исследования авторов будут направлены на практическое решение данных задач.

Список литературы

1. Makarov M., Astafiev A. Synthesis of Special Operating Decisions as Part of Adaptive Control of a Mobile Robot // CEUR Workshop Proceedings. MIP: Computing-V 2022 – Proceedings of the 5th International Scientific Workshop on Modeling, Information Processing and Computing. 2022. P. 12–17.
2. Ульянов С.В., Ульянов В.С. Применение сквозных технологий мягких вычислений в задаче интеллектуального робастного управления одноколесным роботом-велосипедом // Робототехника и техническая кибернетика. 2020. Т. 8, № 2. С. 119-138.

3. Куаншкалиев Т.Х., Рыбаков А.В. Робот-гексапод с нейросетевой системой управления движением // Робототехника и техническая кибернетика. 2017. Т. 16, № 3. С. 59-66.
4. Чернухин Ю.В., Доленко Ю.С., Бутов П.А. Нейросетевой подход к решению задачи локальной навигации интеллектуальными мобильными роботами в условиях, приближенных к реальной среде // Известия ЮФУ. Технические науки. 2013. № 5 (142). С. 80-84.
5. Степанов Д.Н., Смирнова Е.Ю., Горюнов В.В. Когнитивная навигация мобильных роботов с использованием естественных визуальных ориентиров // Робототехника и техническая кибернетика. 2016. №1(10). С. 62-66.
6. Panov A.I., Yakovlev K. Behavior and Path Planning for the Coalition of Cognitive Robots in Smart Relocation Tasks // Robot Intelligence Technology and Applications. 2015. N 4. P. 3–20.
7. Daachi B., Madani T. Adaptive Neural Networks and Robot Intelligent Control in Direct or Indirect Interaction with Humans. Amsterdam : Elsevier. 2019. 120 p.
8. Brink H., Richards J., Fetherolf M. Real-World Machine Learning – Manning. 2016. 427 p.
9. Lu H., Xu X. Artificial Intelligence and Robotics. Berlin : Springer, 2018. 326 p.
10. Bishop C. Pattern Recognition and Machine Learning. Cambridge : MIT Press, 2018. 738 p.
11. Tzafestas S. Introduction to Mobile Robot Control. Amsterdam : Elsevier, 2014. 750 p.
12. Kochenderfer M.J., Wheeler T.A., Wray K.H. Algorithms for Decision Making. Cambridge : MIT Press. 2022. 678 p.
13. Yongxiang Z., Lei Z. Improvement and application of heuristic search in multi-robot path planning // 2017 First International Conference on Electronics Instrumentation & Information Systems (EIIS).
14. Peng Y., Zhang X., Jiang Y., Xu X., Liu J. Leader-Follower Formation Control For Indoor Wheeled Robots Via Dual Heuristic Programming // 2020 3rd International Conference on Unmanned Systems (ICUS). P. 600–605.
15. Карпов В.Э. Об одной реализации знак-ориентированной системы управления мобильного робота // Искусственный интеллект и принятие решений. 2015. № 3. С. 53-61.
16. Осипов В.Ю., Милосердов Д.И. Нейросетевое прогнозирование событий для роботов с непрерывным обучением // Информационно-управляющие системы. 2020. № 5 (108). С. 33–42.
17. Bobyr M.V., Emelyanov S.G. A nonlinear method of learning neuro-fuzzy models for dynamic control systems // Applied Soft Computing. 2020. V. 88. P. 106030.

А.С. НУЖНЫЙ¹, Е.Н. ЛЕВЧЕНКО², А.Ю. ГЛУХОВ²

¹Институт проблем безопасного развития атомной энергетики РАН, Москва

²ООО “ЛУКОЙЛ-Инженерные навыки и компетенции”, Нижний Новгород
nuzhny@inbox.ru

ПОСТРОЕНИЕ НЕЙРОСЕТЕВОЙ МОДЕЛИ ОПТИМАЛЬНОГО УПРАВЛЕНИЯ ПРОЦЕССАМИ НЕФТЕПЕРЕРАБОТКИ

Рассматривается задача оптимального управления НПЗ на примере установки гидрокрекинга гудрона. Строится модель прогноза экономической эффективности установки путем обучения нейронной сети на исторических данных. Оптимизация прогнозной экономики установки по управляющим воздействиям позволяет получить их значения, максимизирующие потенциальную маржинальность. Корректность рекомендаций модели оценивается экспертами, а также путем тестирования непосредственно на установке.

Ключевые слова: *рекуррентные нейронные сети, оптимальное управление, временные ряды.*

Введение

Современный нефтеперерабатывающий завод (НПЗ) представляет собой сложный информационный объект. Все его ключевые узлы снабжены датчиками замеров физических параметров (температур, давлений, потоков), показания с которых снимаются в режиме реального времени. Как правило, это сотни, а иногда и тысячи датчиков, интервал снятия информации с которых может составлять от одной до нескольких минут [1]. Объем получаемой в результате информации вполне соответствует термину BIG DATA. От качества управления этими данными может зависеть безопасность и экономическая эффективность НПЗ.

На низшем уровне НПЗ регулируется системами распределенного управления (PCY), в основе которого лежат каскады ПИД-регуляторов. Последние два десятилетия в производство внедряются системы улучшенного управления технологическими процессами (в литературе для таких систем обычно используется английская аббревиатура APC) [2, 3]. Суть APC в том, что она автоматически ставит задание ПИД-регуляторам, исходя из стоящих перед ней целей. Эти цели задаются оператором установки и состоят, в первую очередь, в ведении режима в рамках допусти-

мых технологических ограничений, а также ограничений, позволяющих соблюдать качество получаемых продуктов. Кроме того, современным APC можно ставить цели на поиск режимов максимальной экономической эффективности, однако, ввиду линейности используемых моделей и отсутствия возможности их автоматического обучения, возможности APC по решению задачи оптимального управления ограничены. В большинстве случаев задача выбора оптимальных установок управления для обеспечения максимального экономического эффекта возлагается на оперативный персонал, и качество этого выбора зависит от многих факторов.

В данной работе строится модель предсказания экономической эффективности НПЗ, а также поиск оптимального управления. Построенная программа работает в режиме системы поддержки принятия решений – дает оператору рекомендации по выставлению таких значений управляющих параметров, которые в дальнейшем должны улучшить экономику установки.

Далее будет описана рассматриваемая в работе установка, дана математическая постановка задачи ее оптимизации, описана модель прогноза поведения установки и приведены результаты тестирования построенного программного решения.

Постановка задачи и описание объекта исследования

В качестве объекта исследования рассматривалась установка гидрокрекинга гудрона, расположенная на заводе компании Лукойл в г. Бургас (Болгария) [1, 4]. Установка состоит из трех частей – реакторного и ректификационного блоков, а также блока регенерации катализатора. В реакторном блоке происходят химические превращения, в результате которых тяжелые фракции углеводородов в результате нагрева и подачи водорода в присутствии катализатора превращаются в легкие. В ректификационном блоке происходит разделение на легкие фракции – бензиновую, дизельную, вакуумный газойль и тяжелые остаточные фракции. Блок регенерации катализатора предназначен для непрерывного восстановления и очищения катализатора, а также добавления в циркуляцию свежего катализатора.

Блоки установки снабжены датчиками, которые (в основном) бывают трех типов – температурные датчики, датчики потока и давления. Общее число датчиков на установке более 1000. Данные в РСУ обновляются по мере изменения значений (не реже 1 раза в секунду). Но запись в систему исторического хранения данных (База данных реального времени – БДРВ) производится с интервалом в одну минуту.

Управление установкой оператор осуществляет с помощью ~ 30 управляющих воздействий. Управление происходит путем выставления целевых значений показателей для некоторых ПИД-регуляторов, после чего в автоматическом режиме происходит корректировка состояния установки таким образом, чтобы показания определенных потоков, температур или давлений приблизились к целевым значениям. Реальные низкоуровневые параметры управления – величины открытия клапанов и задвижек (потоков сырья, подачи топлива в печь и т.д.). Их значения устанавливаются автоматически с помощью ПИД-регуляторов. На рассматриваемой установке не смонтирована система улучшенного управления APC.

Управление установкой преследует две цели: во-первых, установку нужно удерживать в некоторых технологических границах, которые определяются требованиями безопасности режима и требованиями к качеству получаемых продуктов. Первые задаются в виде ограничений на значения показателей некоторых датчиков системы. Вторые определяются постфактум, как показатели лабораторных анализов проб продуктов.

Во-вторых, когда режим безопасности и допусков по качеству достигнут, в рамках этих ограничений желательно выбрать режим наибольшей экономической эффективности. Экономическую эффективность (маржинальность) установки можно выразить, как сумму объемов получаемых продуктов в единицу времени, умноженных на их стоимость, за вычетом затрат на их получение и стоимости сырья.

Виртуальные анализаторы

Продукты, получаемые с блока ректификации, должны отвечать определенным требованиям по качеству. Качество полученного продукта может быть измерено в лаборатории. Стандартной является ситуация, когда по графику лабораторного контроля (один, два или три раза в день) отбираются пробы продуктов, передаются в лабораторию, где проводится анализ. Типичные показатели качества продуктов – фракционный состав продукта, в котором определяющими являются 5%-е и 95%-е температуры выкипания фракций. Они должны находиться в рамках допустимых значений, определенных в спецификации на продукт.

Лабораторный анализ затратен и не может проводиться часто, кроме того, он достаточно продолжителен по времени. От момента взятия пробы до получения результатов может проходить более суток, т. е., если установка вышла за допустимые границы по качеству, оператор узнает об этом с большой задержкой. Однако постфактум мы можем сопоставить показания датчиков установки и значения лабораторных показателей, со-

брав, таким образом, обучающую выборку. На этой выборке можно построить виртуальные анализаторы (ВА) – предиктивные модели, прогнозирующие по состоянию установки значения лабораторных показателей.

При правильной предобработке входных данных (показаний датчиков установки) задача построения ВА сводится к классической постановке задачи регрессии. Подробно методика построения ВА разобрана в работе [1]. Спецификой данной задачи является то, что модели строятся на небольших обучающих выборках, обычно от нескольких десятков до нескольких сотен точек. В этой связи, чтобы избежать переобучения, часто для построения ВА используются простые линейные модели регрессии [5]. Однако, как показано в [1], нелинейные модели при квалифицированном их использовании во многих случаях позволяют достичь существенно большей точности предсказания (в [1] победителем оказался градиентный бустинг на деревьях [6]).

В результате построения ВА будет получена серия ограничивающих условий на состояние установки вида

$$T_i^{\min} < VA_i(\vec{s}_t, \vec{u}_t) < T_i^{\max}, \quad (1)$$

где $\vec{s}_t$ – набор показаний датчиков установки, снятых в момент t , $\vec{u}_t$ – управляющие воздействия в момент t , VA_i – модель виртуального анализатора, $T_i^{\min}$, $T_i^{\max}$ – ограничения сверху и снизу моделируемого показателя, которые нужно будет учесть при решении задачи оптимального управления.

Описание подхода к оптимизации установки

Цель оптимизации установки – повысить ее маржинальность, т.е. найти режим максимальной экономической эффективности в рамках допустимых технологических ограничений и ограничений по качеству. Простейшим решением данной задачи представляется следующее – сначала строится модель прогноза экономики установки на момент $t + \Delta t$ от ее текущего состояния и текущих значений управляющих параметров $E_{t+\Delta t}(\vec{s}_t, \vec{u}_t)$. После чего полученная функция максимизируется по управляющим параметрам $\vec{u}_t$ при дополнительных ограничениях, накладываемых требованиями к режиму установки и ограничениями по качеству.

Функцию предсказания экономики $E_{t+\Delta t}(\vec{s}_t, \vec{u}_t)$ можно построить, решая задачу прогноза временного ряда. Поскольку в дальнейшем эту функцию мы будем использовать для поиска оптимального значения, в качестве аппроксиматора желательно выбрать непрерывную функцию. В частности, здесь не удобны модели, основанные на деревьях решений типа градиентного бустинга [6] или случайного леса [7]. Стандартные оптимизационные методы с ними работают нестабильно. Модель пред-

сказания следует строить, используя аналитические функции, типа нейронных сетей [8] или сетей радиальных базисных функций [9]. С учетом того, что объектом моделирования выступают последовательности, идеальным кандидатом представляется рекуррентная нейронная сеть [8].

Экономика установки представляет собой сумму получаемых продуктов, умноженных каждый на свою стоимость, минус затраты на их получение и стоимость сырья. Таким образом, история изменения экономики установки может быть вычислена на каждом временном шаге и представлена в виде временного ряда, после чего строится модель предсказания этого временно ряда на временной горизонт T от текущего состояния и управляющих воздействий. Затем проводится максимизация интегральной экономики на временном отрезке T :

$$\sum_{t=t}^{t+T} E(\vec{s}_t, \vec{u}_t) \quad (2)$$

по параметрам $\vec{u}_t$.

Следует отметить, что резкое изменение управляющих воздействий недопустимо, так как это может привести к существенным колебаниям состояния установки. Изменения следует производить постепенно, в связи с чем принято решение вместо максимизации (2) решать оптимизационную задачу:

$$(target - \sum_{t=t}^{t+T} E(\vec{s}_t, \vec{u}_t))^2, \quad (3)$$

где *target* превосходит текущую интегральную экономику на небольшую величину:

$$target = (1 + \epsilon) \sum_{t=t}^{t+T} E(\vec{s}_t, \vec{u}_t)$$

при дополнительных условиях, обусловленных технологическими ограничениями вида

$$s_t^j < T_j,$$

и ограничениями по качеству, имеющими вид (1). Другими словами, нужно подобрать такие значения $\vec{u}_t$, которые будут не сильно увеличивать экономику, но при этом также не сильно изменят значения управляющих воздействий. Через некоторое время после изменений управляющих параметров, когда установка придет в равновесие, процедуру максимизации экономики можно будет повторить.

Модель предсказания экономики установки

Решение задачи оптимального управления определяется, по сути, тем, насколько качественно будет решена задача предсказания экономики. Задача прогноза экономики формулируется следующим образом: требует-

ся предсказать временной ряд $(x_t, \dots, x_{t+T})$ по его истории $(x_{t-\Delta}, \dots, x_t)$ и управляющим воздействиям $\vec{u}_t$. Прогноз временного ряда на несколько шагов вперед можно проводить последовательно – подать на вход модели историю до момента времени t , получить прогноз следующего шага:

$$(x_{t-\Delta t}, \dots, x_t, \vec{u}_t) \Rightarrow x_{t+1}.$$

Добавить ко входу спрогнозированное значение x_{t+1} и построить прогноз следующего шага:

$$(x_{t-\Delta+1}, \dots, x_{t+1}, \vec{u}_{t+1}) \Rightarrow x_{t+2},$$

и так далее:

$$(x_{t-\Delta+T-1}, \dots, x_{t+T-1}, \vec{u}_{t+T-1}) \Rightarrow x_{t+T}.$$

Однако такой подход не позволяет учесть то обстоятельство, что управляющие воздействия оказывают влияние на поведение временного ряда с некоторой задержкой (лагом). Изменение одних управляющих воздействий оказывает влияние на временной ряд практически сразу, других – с интервалом в несколько часов. Таким образом, для полноценного прогноза в модели должен быть предусмотрен механизм «запоминания» значений управляющих воздействий, имеющих место несколько шагов назад.

Решение этой проблемы может быть следующим: модель строит предсказание нескольких скрытых временной рядов

$$\begin{aligned} z_{t+\Delta t+1}^1 &= f_1(\vec{x}_t, \vec{u}_{t+\Delta t}, \vec{w}_1), \\ z_{t+\Delta t+1}^2 &= f_2(\vec{x}_t, \vec{u}_{t+\Delta t}, \vec{w}_2), \\ &\vdots \\ z_{t+\Delta t+1}^M &= f_M(\vec{x}_t, \vec{u}_{t+\Delta t}, \vec{w}_M). \end{aligned}$$

Значения же наблюдаемой последовательности x_t выражаются через скрытые z , взятые с некоторым (каждая со своим) лагом:

$$x_{t+\Delta t} = g(z_{t+\Delta t-lag1}^1, z_{t+\Delta t-lag2}^2, \dots, \vec{a}).$$

Схематически эта идея представлена на рис. 1.

Параметры $\vec{w}_i$ и $\vec{a}$ являются адаптивными параметрами модели, их значения определяются путем минимизации ошибки предсказания временного ряда на обучающей выборке. При обучении предиктивной модели значения управляющих параметров на каждом временном шаге $\vec{u}_{t+\Delta t}$ берутся из истории работы установки.






Рис. 1. Схема модели предсказания. Наблюдаемая величина x_t является суперпозицией скрытых компонент z_t^i , взятых каждая со своим лагом

Оценка качества оптимизации

Оценку качества работы модели можно провести несколькими способами: во-первых, выполнить натурный эксперимент – в процессе управления установкой последовать рекомендациям модели и оценить, как при этом изменится экономика. Это способ, который дает однозначный вердикт для модели, но он и самый дорогой. Приступать к натурным испытаниям допустимо только после тщательной предварительной проверки, обладая достаточной степенью доверия к модели. Во-вторых, сопоставить рекомендации модели с рекомендациями экспертов. И в-третьих, поскольку поиск управляющих воздействий ведется путем максимизации прогноза маржинальности, необходимо оценить качество данного прогноза. Оценку качества рекомендаций по установке управляющих воздействий третий вариант не дает, но он позволяет провести оценку промежуточного результата, от которого напрямую зависит качество рекомендаций по управлению.



а)



б)

Рис. 2. Примеры прогноза экономики модели. Сплошная линия – прогноз модели, прерывистая – исторический график экономики. По оси абсцисс отложено время в минутах, по оси ординат – выручка в долларах в час

Оценку точности прогноза модели можно провести на исторических данных. На рис. 2. приведены примеры прогноза экономики установки на горизонте 6 часов. Качество прогноза можно считать вполне приемлемым, модель хорошо улавливает крупномасштабные тренды временного ряда, с

приемлемой точностью описывает колебания графика, связанные с колебаниями процессов на установке. Показатель R-квадрат точности прогноза интегральной экономики (2) $R^2 \sim 0.96$.

Экспертный анализ рекомендаций системы позволил заключить осмысленность даваемых моделью рекомендаций.

Проведенные на данный момент эксперименты на установке показали статистически значимое увеличение маржинальности ее работы при следовании рекомендациям модели.

Заключение

Рассмотрена задача построения модели оптимального управления НПЗ. Созданная программа работает по принципу программы поддержки принятия решений – дает оператору установки рекомендации по изменению управляющих воздействий, которые должны привести к состоянию с большей маржинальностью. Оптимальные значения управляющих параметров ищутся путем максимизации прогнозной маржинальности установки. Для построения ее прогноза использовалась рекуррентная нейросетевая модель. Эксперименты показали, что модель прогнозирует будущую экономику установки с хорошей точностью, а рекомендации по корректировке управляющих воздействий согласуются с мнениями экспертов и подтверждаются в натурном эксперименте.

Список литературы

1. Нужный А.С., Однолько И.С., Глухов А.Ю., Пискунов И.В., Вышинский И.М., Левченко Е.Н., Стариков А.С. Использование методов машинного обучения для прогнозирования содержания седиментов (НФТ) в неконвертируемом остатке с установки гидрокрекинга гудрона // Нефтепереработка и нефтехимия. Научно-технические достижения и передовой опыт. 2020. № 7. С. 1–8.
2. Шумихин А.Г., Мусатов Д.А., Власов С.С., Немтин А.М., Плехов В.Г. Опыт разработки и внедрения систем усовершенствованного управления технологическими процессами нефтепереработки на базе виртуальных анализаторов качества // Вестник Пермского национального исследовательского политехнического университета. Химическая технология и биотехнология. 2016. № 2. С. 39–53.
3. Ицкович Э.Л., Дозорцев В.М., Кнеллер В.В. Усовершенствованное управление технологическими процессами (АРС): 10 лет в России // Автоматизация в промышленности. 2013. № 1. С. 12–19.
4. Нужный А.С., Однолько И.С., Глухов А.Ю., Бутырин М.С., Левченко Е.Н., Стариков А.С., Карасев И.В., Лапинова С.А. Оптимизация содержания седиментов в процессе гидрокрекинга гудрона с использованием методов машинного обучения // Прикладная математика и вопросы управления. 2021. № 1.

5. Себер Дж. Линейный регрессионный анализ. Москва : Мир. 1980. 456 с.
6. Friedman J.H. Greedy function approximation: a gradient boosting machine // The Annals of Statistics. 2001. V. 29, N 5. P. 1189–1232.
7. Hastie T., Tibshirani R., Friedman J. Chapter 15. Random Forests // The Elements of Statistical Learning: Data Mining, Inference, and Prediction. Springer-Verlag. 2009. 746 p.
8. Гудфеллоу Я., Бенджио И., Курвилль А.Г. Глубокое обучение. Москва : ДМК, Пресс. 2018. С. 316 – 351.
9. Нужный А.С. Байесовский подход к регуляризации задачи обучения сети функций радиального базиса // Искусственный интеллект и принятие решений. 2015. № 2. С. 18–24.

К.В. СОБЯНИН, Е.И. РУСАКОВА

Национальный исследовательский университет «Высшая школа экономики»,
Пермский филиал
elena.rusakova.2000@mail.ru

**ПРИМЕНЕНИЯ КОМБИНИРОВАННЫХ ФУНКЦИЙ
ПОТЕРЬ И МЕТРИКИ ПРИ ОБУЧЕНИИ U-NET В ЗАДАЧЕ
СЕМАНТИЧЕСКОЙ СЕГМЕНТАЦИИ ОЧАГА ОМНК**

Рассматривается задача семантической сегментации очагов ишемического инсульта на МРТ снимках. Были предложены и применены комбинированная функция потерь и метрики. Была обучена и протестирована U-Net-модель с предобученным на базе ImageNet кодировщиком EfficientNet B4. На тестовых данных модель показала коэффициент Дайса равный 66% для снимков с очагами ишемического инсульта.

Ключевые слова: *нейронные сети, семантическая сегментация.*

Введение

Машинное обучение активно используется в области персонализированной медицины и позволяет повысить качество оказываемых медицинских услуг и снизить расходы. Одной из наиболее актуальных задач является лечение и профилактика инсульта. Острый ишемический инсульт – одна из наиболее частых причин смертности и инвалидности во всем мире. При этом наиболее опасным оказывается повторный инсульт, возникновение которого можно избежать если определить причину первого и принять необходимые профилактические меры.

По статистике среди ишемических инсультов примерно треть имеют неизвестную природу. По характеру лечения ишемические инсульты условно можно разделить на 3 типа: лакунарный – проявление церебральной болезни мелких сосудов, кардиоэмболический – вызванный закупоркой крупного кровяного русла сгустком свернувшейся крови, некардиоэмболический – закупорка фрагментом атеросклеротической бляшки. При этом лакунарный инсульт довольно легко определить по КТ- или МРТ-снимку. Последние два типа, как правило, отличают по другим биомаркерам и дополнительным исследованиям, которые могут затянуться или не привести к положительному результату.

С точки зрения протекания заболевания, приведшего к инсульту, все три типа довольно сильно отличаются, и поэтому характер очага пораже-

ния инсульта может быть полезен при определении этиологии инсульта. Первым шагом к определению этиологии является задача локализации очага инсульта на снимке. Фактически эта задача сводится к задаче бинарной семантической сегментации, которая хорошо решается современными средствами deep learning.

В рамках данной работы модель была обучена на DWI снимках, которые были получены от неврологического отделения городской клинической больницы № 4 города Перми. Обзор опубликованных статей [1–6] показал, что DWI является эффективным методом визуализации для сегментации области инсультного поражения. DWI показывает величину диффузии в некоторых фиксированных направлениях, в качестве метрики используют так называемую фрактальную анизотропию (FA), которая фактически является показателем густоты расположения нервных трактов.

Задача семантической сегментации очагов ишемического инсульта (далее сегментации очагов) является актуальной, и за последнее десятилетие было проведено большое количество исследований, которые были направлены на то, чтобы обеспечить более точную локализацию очага ИИ. В последние годы, с развитием методов и подходов deep learning, решения для задачи сегментации очагов стали более совершенными, что внесло свой вклад в медицинские исследования [1–6]. Обзор литературы показал, что коэффициенты Дайса 60% и 72% на тестовой выборке достигались при использовании решения на основе U-Net сети [4, 6]. Применение более сложной комбинированной функции потерь и предобученного кодировщика может улучшить качество моделей. Стоит отметить, что в качестве метрик для оценки качества полученных моделей чаще всего используют коэффициенты Дайса и Жаккара (IOU). Однако данные метрики не подходят для оценки качества масок сегментации для снимков без очагов ИИ, в статье предлагается новый подход к оценке качества модели.

Постановка задачи

Определение границ очага ИИ на снимках сводится к задаче бинарной семантической сегментации. На вход модели подается снимок в виде массива натуральных чисел размера 256 на 256, на выходе получается изображение того же разрешения со значениями, указывающими на принадлежность пикселя очагу (рис. 1). Большая часть встречающихся снимков не содержит очагов, при этом нужно адекватно оценить качество модели.

Для оценки качества алгоритмов семантической сегментации чаще всего в рассмотренных научных статьях [1–6] использовались коэффициенты Дайса (Dice coefficient) и Жаккара (Jaccard similarity coefficient).




Рис. 1. Изображение и маска сегментации

Данные коэффициенты сходства являются мерой связи предсказанной маски сегментации и исходной маски. Однако, коэффициенты Дайса и Жаккара будет полезно считать только для снимков с очагами. В данной статье будет рассмотрен другой подход к оценке качества модели.

Исходный набор данных и аугментации

В рамках данной работы модель была обучена на DWI-снимках, которые были получены от неврологического отделения городской клинической больницы № 4 города Перми. Обзор опубликованных статей [1–6] показал, что DWI является эффективным методом визуализации для сегментации области инсультного поражения. DWI показывает величину диффузии в некоторых фиксированных направлениях, в качестве метрики используют так называемую фрактальную анизотропию (FA), которая фактически является показателем густоты расположения нервных трактов.

Обучающий набор данных представляет из себя DWI снимки головного мозга 51-го пациента в формате nifti. Каждый снимок представляет собой набор из 25 сечений размером 256 на 256 пикселей, для каждого из которых задана разметка в виде бинарной маски того же разрешения. Очаг на снимках присутствует примерно в 16% слоев.

Исходный набор данных (51 пациент) был разделен на обучающий и валидационный в соотношении 80% и 20% соответственно, таким образом, чтобы снимки одного и того же пациента не оказались как в обучаю-

щем, так и в валидационном наборах данных. К данным из обучающего набора с вероятностью в 50% была применена аугментация Vertical Flip, при которой полушария менялись местами.

Метрики для оценки качества модели и комбинированная функция потерь

Коэффициент Серенсена – Дайса – это статистический показатель, используемый для оценки сходства двух выборок [7]:

$$Dice\ Coefficient = 2 * \frac{|A \cap B|}{|A| + |B|}. \quad (1)$$

Здесь $|A|$ и $|B|$ являются мощностями двух наборов (т. е. количеством элементов в каждом наборе). Коэффициент Дайса равен удвоенному количеству элементов, общих для обоих наборов, деленному на сумму количества элементов в каждом наборе [7]. Он отличается от коэффициента Жаккара, который подсчитывает истинные положительные результаты только один раз как в числителе, так и в знаменателе:

$$Jaccard\ Coefficient = \frac{|A \cap B|}{|A| + |B| - |A \cap B|}. \quad (2)$$

Здесь $|A|$ и $|B|$ также являются мощностями двух наборов (т. е. количеством элементов в каждом наборе). Оба описанных коэффициента могут принимать значения от 0 до 1. Чем ближе к 1 будут значения коэффициентов, тем лучше модель будет предсказывать границы очага поражения мозга на DWI снимках. Стоит отметить ограничения, которые накладывает специфика задачи семантической сегментации очагов ИИ. В наборе данных снимков без очага будет в несколько раз больше, чем снимков с очагами. Поэтому при подсчете метрик Дайса и Жаккара на снимках без очагов и предсказаниях без очагов в знаменателе у метрик будет 0 – так как на изображениях не будет пикселей с очагом. Следовательно, коэффициенты Дайса и Жаккара будет полезно считать только для снимков с очагами. Для снимков без очагов необходимо будет подобрать другую метрику.

Предложенный подход по оценке качества модели учитывает то, что для снимков без очагов коэффициент Дайса не подходит, для каждого из изображений предлагается считать определенную метрику:

1. Для предсказаний модели, на которых должен быть очаг, когда на маске он есть, рассчитывать коэффициент Дайса.

2. Для предсказаний модели с ложными срабатываниями, когда очага нет на маске, считать долю верно предсказанных пикселей (Pixel Accuracy) с коэффициентом в числителе.

Было решено использовать функцию потерь, которая будет похожа на применяемые метрики. В данном случае это позволило улучшить сходимость и качество модели. В качестве функции потерь была использована модифицированная Dice-BCE Loss [8]. Эта функция потерь сочетает в себе Dice Loss со стандартной двоичной кросс-энтропии (Binary Cross-Entropy, BCE).

В отличие от стандартной Dice-BCE Loss, в созданной Dice-BCE-Accuracy Loss дополнительно считается Pixel Accuracy Loss для всех снимков. Учитывается доля неверно предсказанных пикселей, так как мы заинтересованы в том, чтобы модель не предсказывала очаги на изображениях без очагов. Чем меньше значение Pixel Accuracy Loss – тем лучше, так как мы стремимся минимизировать ложные предсказания. Созданная функция потерь в результате выдает сумму BCE, Dice Loss и Pixel Accuracy Loss, с заданными коэффициентами (0,6; 0,3 и 0,1 соответственно):

$$BCE = -\frac{1}{N}(pt * \log(pp) + (1 - pt) * \log(1 - pp)) . \quad (3)$$

Здесь pt – бинарная целевая маска (Ground Truth);

pp – маска прогноза сети;

N – количество выходных масок прогноза сети.

$$Dice\ Loss = 1 - 2 * \frac{\sum pp * pt}{\sum pp + \sum pt} \quad (4)$$

Здесь pt – бинарная целевая маска (Ground Truth);

pp – маска прогноза сети.

$$Accuracy\ Loss = 1 - \frac{TP + TN}{TP + TN + FP + FN} \quad (5)$$

Здесь TP – количество пикселей, на которых спрогнозирован очаг, при этом очаг есть на соответствующих пикселях целевой маски (True Positive);

TN – количество пикселей, на которых не спрогнозирован очаг, при этом очага нет на соответствующих пикселях целевой маски (True Negative);

FP – количество пикселей, на которых спрогнозирован очаг, при этом очага нет на соответствующих пикселях целевой маски (False Positive);

FN – количество пикселей, на которых не спрогнозирован очаг, при этом очаг есть на соответствующих пикселях целевой маски (False Negative).

$$\begin{aligned} Dice-BCE-Accuracy\ Loss = & BCE * 0,6 \\ & + Dice\ Loss * 0,3 \\ & + Accuracy\ Loss * 0,1 \end{aligned} \quad (6)$$

Коэффициенты (0,6; 0,3 и 0,1) были подобраны для того, чтобы каждая из функций потерь стремилась к 0 в процессе обучения модели постепенно и независимо от остальных.

Модель с предобученным кодировщиком

Архитектура сети U-Net представляет собой полносвёрточную сеть (FCN), модифицированную так, чтобы показывать более высокую точность в задачах сегментации. Данная архитектура была описана в статье 2015-го года [9]. U-Net способна учиться на относительно небольшом обучающем наборе. Когда U-Net обучается с нуля, сначала веса инициализируются случайным образом. Обучающая сеть без переобучения набора данных должна быть относительно большой, состоящей из миллиона изображений. Сети, обученные на наборе данных ImageNet, широко используются в качестве источника инициализации для сетевых весов в разнообразных задачах. Таким образом, процедуру обучения можно провести для нескольких необученных слоев сети (иногда только для последнего слоя) с учетом особенностей набора данных. Предобученный кодировщик ускоряет обучение даже на наборах данных с разными семантическими характеристиками.

Наилучший результат для решения поставленной задачи показала модель с предобученным кодировщиком EfficientNet B4. Веса данной сети были инициализированы с помощью семнадцати миллионов изображений из набора ImageNet. Модель EfficientNet была предложена Таном в 2019-м году [10]. EfficientNet предоставляет возможность масштабирования по глубине, ширине и разрешению изображений. В табл.1 представлена архитектура EfficientNet B4 сети [11].

Таблица 1

Архитектура EfficientNet B4

Stage	Operator	Resolution	Channels	Layers
1	Conv3 x 3	380 x 380	45	1
2	MBConv1, k3 x 3	190 x 190	22	2
3	MBConv6, k3 x 3	190 x 190	34	4
4	MBConv6, k5 x 5	95 x 95	56	4
5	MBConv6, k3 x 3	95 x 95	112	5
6	MBConv6, k5 x 5	48 x 48	157	5
7	MBConv6, k5 x 5	48 x 48	269	7
8	MBConv6, k3 x 3	24 x 24	448	2
9	Conv1 x 1&Pooling&FC	24 x 24	1792	1

Основной блок архитектуры сети включает inverted residual блок MBConv. Традиционный residual блок имеет на входе большое количество каналов, которые сжаты сверткой 1×1 . Затем количество каналов снова увеличивается с помощью свертки 1×1 . Inverted residual блок следует обратному подходу. Сначала число каналов расширяется с помощью свертки 1×1 , затем используется свертка 3×3 по глубине (которая значительно уменьшает количество параметров), затем применяется свертка 1×1 , которая уменьшает количество каналов.

Полученные результаты

U-Net сеть была обучена на обучающем наборе данных за 13 эпох. В качестве оптимизатора для данной нейронной сети был использован Adam с learning rate равным $1e-4$. Качество модели проверялось на каждой эпохе обучения на обучающем наборе данных. Для ускорения времени обучения модели использовалась CUDA (Compute Unified Device Architecture), которая позволяет существенно увеличить вычислительную производительность благодаря использованию графических процессоров Nvidia. Использование CUDA также позволило увеличить размер батча для обучения модели до 24.

Значение функции потерь при обучении нейронной сети уменьшилось с 0,841 до 0,467 (рис. 2). При этом Pixel Accuracy Loss с 0,164 падает до 0, Dice Loss с 0,995 на первой эпохе доходит до 0,170, а BCE начинает с 0,877, на восьмой эпохе доходит до 0,692.




Рис. 2. Значение функции потерь на эпохах обучения модели

Построенная и обученная модель была оценена по результатам на валидационной выборке (которая составляет 20% от исходной). Коэффициент Дайса (для снимков с очагами) для созданной модели представлен в табл. 2.

Таблица 2

Метрики для U-Net модели

	Dataset	U-Net
Dice	Train	0,84
	Test	0,66

Заключение

Была реализована модель для сегментации очагов ишемического инсульта – U-Net с предобученным на базе ImageNet кодировщиком EfficientNet B4. Была предложена и реализована новая комбинированная функция потерь Dice-BCE-Accuracy Loss, применение которой помогло улучшить качество модели. Был предложен новый подход к оценке качества модели, в частности подсчет коэффициента Дайса только для снимков с очагами. Модель показала значение коэффициента Дайса на валидационной выборке около 66%. Созданную модель, после ее совершенствования с помощью грамотного подбора аугментаций, заморозки весов при обучении и других подходов, можно будет использовать для разметки DWI снимков или для обучения созданной модели на КТ-снимках. Иссле-

дование можно продолжить и расширить до определения этиологии очага ишемического инсульта (задача многоклассовой семантической сегментации).

Список литературы

1. Chen L., Bentley P., Rueckert D. Fully automatic acute ischemic lesion segmentation in DWI using convolutional neural networks // *NeuroImage: Clinical*. 2017. V. 15. P. 633–643.
2. Joshi S., Gore S. Ischemic stroke lesion segmentation by analyzing mri images using dilated and transposed convolutions in convolutional neural networks // *2018 Fourth International Conference on Computing Communication Control and Automation (ICCCUBEA)*. IEEE. 2018. P. 1–5.
3. Zhang R. [et al.]. Automatic segmentation of acute ischemic stroke from DWI using 3-D fully convolutional DenseNets // *IEEE transactions on medical imaging*. 2018. V. 37, N 9. P. 2149–2160.
4. Liu P. Stroke lesion segmentation with 2D novel CNN pipeline and novel loss function // *International MICCAI Brainlesion Workshop*. Springer, Cham. 2018. P. 253–262.
5. Zhang L. [et al.]. Ischemic stroke lesion segmentation using multi-plane information fusion // *IEEE Access*. 2020. V. 8. P. 45715–45725.
6. Wang G. [et al.]. Automatic ischemic stroke lesion segmentation from computed tomography perfusion images by image synthesis and attention-based deep neural networks // *Medical Image Analysis*. 2020. V. 65. P. 101787.
7. Thada V., Jaglan V. Comparison of jaccard, dice, cosine similarity coefficient to find best fitness value for web retrieved documents using genetic algorithm // *International Journal of Innovations in Engineering and Technology*. 2013. V. 2, N 4. P. 202–205.
8. Lei T. [et al.]. Medical Image Segmentation Using Deep Learning: A Survey. 2020.
9. Ronneberger O., Fischer P., Brox T. U-net: Convolutional networks for biomedical image segmentation // *International Conference on Medical image computing and computer-assisted intervention*. Springer, Cham. 2015. P. 234–241.
10. Tan M., Le Q. Efficientnet: Rethinking model scaling for convolutional neural networks // *International conference on machine learning*. PMLR, 2019. P. 6105–6114.
11. Zhang P., Yang L., Li D. EfficientNet-B4-Ranger: A novel method for greenhouse cucumber disease recognition under natural complex environment // *Computers and Electronics in Agriculture*. 2020. V. 176. P. 105652.

Б.А. СТАРОВЕРОВ, В.В. ОЛОНICHEВ, С.Д. ТАРАСОВ

Костромской государственной университет
sba44@mail.ru

НЕЙРОСЕТЕВЫЕ ПОСЛЕДОВАТЕЛЬНЫЕ МЕТОДЫ ПАРАМЕТРИЧЕСКОЙ ИДЕНТИФИКАЦИИ ДИНАМИЧЕСКИХ ПРОЦЕССОВ

Рассматриваются варианты идентификации параметров функций, аппроксимирующих временные ряды, а также нелинейных динамических объектов посредством нейронных сетей. На основе методики глубокого обучения с использованием библиотеки TensorFlow предложен квазирезервуарный последовательный метод идентификации параметров аппроксимирующих функций и схема его реализации с помощью двух нейронных сетей – имитационной и идентификационной. Также рассмотрена последовательно-параллельная идентификация нелинейных динамических объектов. Представлены результаты исследования. Обоснована возможность применения данных методов и представлены практические результаты исследования. Установлено, что рассматриваемые методы обладают большей эффективностью по сравнению с методом прямой параметрической идентификации с помощью нейронных сетей.

Ключевые слова: *временной ряд, аппроксимирующая функция, нелинейный динамический объект, нейронные сети, резервуарные вычисления, последовательные и параллельные схемы идентификации*

Введение

Методы машинного обучения, в частности, нейронные сети, в настоящее время получили широкое распространение в различных областях науки и техники. В самостоятельное направление можно выделить идентификацию динамических процессов для прогнозного и адаптивного управления [1–4]. В этом направлении определенную специфику имеют два вида задач: параметрическая идентификация аппроксимирующей экспериментальные данные функции временных рядов и идентификация динамических объектов управления.

Для изучения свойств сложных систем, в том числе при экспериментальных исследованиях, используется подход, основанный на анализе сигналов, полученных на выходе системы. Это актуально в тех случаях, когда математически описать изучаемый процесс практически невозможно.

но. Исходные данные в данном случае – это наблюдаемая величина в виде массива из n чисел, представляющих собой значения измеренной (наблюдаемой) динамической переменной $x(t)$ с постоянным шагом τ по времени $t_i = (i - 1)\tau$: $x_i = x(t_i)$, $i = 1, 2, \dots, n$.

В анализе временных рядов выделяются две основные задачи: задача идентификации и задача прогноза [5, 6]. При решении задач прогнозирования для упрощения технологии глубокого обучения используется декомпозиционный метод обучения сложной нейронной сети путем применения ансамбля более простых по структуре сетей [5–7]. Другой метод прогноза имеет целью по данным наблюдений предсказать будущие значения измеряемых характеристик изучаемого объекта, осуществляемое путем определения параметров аппроксимирующей экспериментальные данные функции (АЭДФ), рекуррентно устанавливающей следующее значение временного ряда по нескольким предыдущим [8, 9].

При синтезе регуляторов для систем автоматического управления различными техническими объектами первоочередной задачей является идентификация параметров объекта по экспериментальным данным. Сам объект при этом, как правило, является нелинейным.

В зависимости от характера нелинейности различают три типа моделей [4], для которых формулы (1) – (3) позволяют вычислить прогнозируемые значения на выходе объекта управления по данным временного ряда:

$$y(k+1) = \sum_{i=0}^{n-1} a_i y(k-i) + f_1[u(k), u(k-1), \dots, u(k-m+1)]; \quad (1)$$

$$y(k+1) = f_2[y(k), y(k-1), \dots, y(k-n+1)] + \sum_{i=0}^{m-1} b_i u(k-i); \quad (2)$$

$$y(k+1) = f_2[y(k), y(k-1), \dots, y(k-n+1)] + f_1[u(k), u(k-1), \dots, u(k-m+1)]. \quad (3)$$

Решение данных задач насчитывает уже не один десяток лет. Однако в настоящее время появились возможности их решения значительно более эффективно и оперативно, так как разработаны методики глубокого нейронного обучения, которые стали общедоступными и достаточно простыми в использовании. Это обусловлено тем, что создана библиотека TensorFlow [10, 11], которая опубликована под открытой лицензией, а также разработана библиотека Keras [12], создающая удобный и интуитивно понятный интерфейс для TensorFlow для языка программирования Python, сохраняя при этом возможности использования практически всех мощных и гибких инструментов TensorFlow. На основе использования данных инструментов предлагается метод параметрической идентификации

ции АЭДФ и идентификации нелинейного объекта, с целью получения его имитационной модели.

Параметрическая идентификация аппроксимирующих функций временных рядов

Как уже отмечалось, задачи для идентификации и предполагают ответ на вопрос, каковы параметры системы, породившей временной ряд. Для этого требуется определить параметры АЭДФ. В качестве таких аппроксимирующих функций чаще всего применяются следующие: линейная: $y = a \cdot x + b$; парабола второго и более высоких порядков: $y = a_0 + \dots + a_n x^n$; гиперболическая: $y = \frac{a}{x} + b$; степенная: $y = a \cdot x^b$; экспоненциальная: $y = e^{ax+b}$; показательная: $y = a \cdot b^x$.

Нахождение множества параметров $\mathbf{Q} = [a, b]$ АЭДФ посредством нейронных сетей производится в два этапа. На первом этапе производится обучение нейронной сети. Входной вектор формируется из массива значений временного ряда $X = [x_1 x_2 \dots x_n]$, по которым определены параметры АЭДФ. Выходной обучающий вектор формируется из множества параметров $\mathbf{Q}$, соответствующих этим значениям временного ряда. Обучение осуществляется по всему возможному диапазону изменения параметров АЭДФ. На втором этапе осуществляется идентификация параметров для значений, полученных из новых экспериментальных данных, не содержащихся в обучающей выборке.

Рассмотренный алгоритм получения параметров представляет собой метод прямой нейронной идентификации. Данный метод имеет существенный недостаток, который заключается в том, что для идентификации параметров функции на вход обученной нейронной сети необходимо подавать входной вектор, имеющий размерность n , который может насчитывать несколько десятков и даже сотен значений экспериментальных данных. А это, в свою очередь, приводит к проблемам с размерностью нейронной сети. Во входном слое и внутренних слоях будет насчитываться большое количество нейронов, что требует, в свою очередь, достаточно большого массива обучающей выборки. Возникает также самостоятельная проблема определения наиболее эффективного типа и структуры такой нейронной сети.

Устранить данные недостатки способен метод биактивной нейронной идентификации [13, 14]. Данный метод базируется на идее резервуарных вычислений [15–17].

Резервуарные вычисления представляют расширение возможностей нейронных сетей, в которых входной сигнал связан динамической систе-

мой (резервуаром). По методу резервуарных вычислений идентификация раскладывается на два процесса: формирование резервуара и непосредственная идентификация. Резервуарные вычисления предполагают применение динамических нейронных сетей. Однако данный метод можно распространить на статические модели. Таким образом, получаем квазирезервуарное вычисление, получившее название биективного, как содержащего взаимно однозначное отражение.

Биективный метод параметрической идентификации предполагает применение двух нейронных сетей (см. рис. 1).




Рис. 1. Функциональная схема биективной нейроидентификации параметров (ИНС_{им} – искусственная имитационная нейросеть; ИНС_{ин} – искусственная идентификационная нейросеть)

Первую нейронную сеть по выполняемой функции можно условно назвать имитационной, вторую – идентификационной. На вход имитационной нейронной сети последовательно подается скалярная динамическая переменная $x(t_i), i = 1, 2, \dots, n$, на выход – значение y , соответствующее входной переменной для данной АЭДФ. В результате процесса обучения нейронная сеть будет представлять собой имитационную модель аппроксимирующей функции:

$$y(x) = f(x_1, x_2, \dots, x_n) = f^b \sum_{j=1}^p w_j f^a \left(\sum_{i=0}^n w_{ij} x_i \right) \quad (4)$$

В случае, когда функции активации скрытого и выходного слоев являются линейными, выражение (4) примет следующий вид:

$$\hat{y}(x) = f(x_1, x_2, \dots, x_n) = \sum_{j=1}^p w_j \sum_{i=0}^n w_{ij} x_i. \quad (5)$$

Как следует из (5), множество параметров аппроксимирующих функций биективно преобразуются во множество синаптических коэффициен-

тов нейросетевой модели. Для однозначного преобразования, очевидно, нейросеть должна быть переобучена.

Из множества синаптических коэффициентов и смещений формирует-ся входной вектор $W = [w_{10} w_{11} \dots w_p]$ для второй идентифицирующей нейросети. Обучающее множество, в свою очередь, формируется из множества входных векторов, получаемых от первой нейронной сети для различных значений параметров АЭДФ. Таким образом, вторая нейросеть будет биективно преобразовывать множество входных сигналов во множество параметров АЭДФ.

В качестве примера рассмотрим биективную идентификацию параметров простейшего полинома первой степени: $y = a \cdot x + b$.

Предварительно создается обучающая выборка. В обучающую выборку в данном случае будут входить таблица значений параметров a и b , а также матрица, состоящая из значений применения данной функции к массиву фиксированной длины x .

Результаты практической реализации биективного метода идентификации

Для эксперимента принимается динамический ряд с шагом 0,05 и длиной в 8 отсчетов: $x_i = x(t_i) = 0,05; 0,15; \dots; 0,4$. Параметры a, b варьируются от 0,1 до 1 с шагом 0,1.

Первая нейронная сеть, выполняющая роль имитационной модели аппроксимирующей функции, состоит из небольшого количества элементов. Данная нейронная сеть имеет два входа – массив значений x и единица. Нейронная сеть должна с большой точностью аппроксимировать значения функции за счет переобучения: количество обучающих выборок должно быть больше количества настраиваемых синаптических коэффициентов. Из значений синаптических весов и смещений обученной нейронной сети формируется резервуар в виде матрицы, которая является входным вектором идентификационной нейронной сети. В соответствии со структурой имитационной нейронной сети он будет содержать 13 элементов. Объем обучающей выборки составляет 100.

Структура идентификационной нейронной сети определялась путем проведения вычислительных экспериментов. В результате определено, что функции активации первой нейронной сети зависят от типа АЭДФ. Для линейных и синусоидальных функций наибольшая точность достигается при использовании линейных функций активации, для экспоненциальных функций наибольшая точность аппроксимации достигается при использовании экспоненциальных и сигмоидальных функций активации.

Наибольшая точность идентификации параметров функций второй нейронной сетью обеспечивается при использовании двух внутренних слоев, в каждом из которых содержится по 10 нейронов с линейными функциями активации.

Метод биактивной нейронной идентификации показал достаточно высокую точность для различных типов функций. Так, отклонение вычисленных параметров от истинных значений данных параметров для полинома (3) составило 5% и 7% для a и b соответственно. Для функции синуса $y = a \cdot \sin(bx)$ такое отклонение составило 6% и 10% для a и b . Для экспоненты $y = a \cdot e^{bx}$ отклонения составили 2% для a и 3% для b .

Для полинома $y = ax^2 + bx + c$ даже при объеме выборки 100, что актуально при оперативной идентификации (размер полной выборки составляет 1000) отклонения для коэффициента b составили 10% для a , 7% для b и 14% для c .

Последовательно-параллельная идентификация нелинейного объекта

Идентификация нелинейного объекта управления при помощи нейронной сети осуществляется, как правило, с целью получения модели, пригодной в дальнейшем для настройки регулятора. Нелинейный объект управления, описываемый уравнением (2), может быть представлен в виде последовательно соединенных блоков – линейного и нелинейного (рис. 2). Подобная декомпозиция может быть применена и для моделей, описываемых уравнениями (1) и (3).




Рис. 2. Нелинейный объект управления

Для проведения эксперимента взят объект третьего порядка. Линейная часть имеет следующие коэффициенты непрерывной передаточной функции:

$$a_0 = 1,000; a_1 = 1,295; a_2 = 1,999; a_3 = 0,716;$$

$$b_1 = 0,285; b_2 = 1,428; b_3 = 0,518.$$

С данными коэффициентами характеристическое уравнение модели имеет один действительный и два комплексно-сопряженных корня, а также переходную характеристику с ярко выраженной колебательностью.

Нелинейная часть является безынерционной и имеет характеристику, представленную на рис. 3.




Рис. 3. Характеристика нелинейной части



Для построения нейронной сети был использован последовательный программный интерфейс библиотеки Keras. Входной слой имел размерность 6, что соответствует объекту 3-го порядка, а выходной 1, что соответствует имитационной модели вход-выход.

В ходе исследования изменялись количество скрытых слоёв, количество нейронов в каждом слое, функция активации нейронов, а также количество эпох для обучения нейронной сети. Было выяснено, что, начиная с трёх скрытых слоёв с количеством нейронов 64-96-64, а также количества эпох, равном 160, при повторных запусках программы получаются устойчиво повторяющиеся результаты.

Для тестирования обученной нейронной сети использовались как последовательно-параллельная, так и параллельная схема. Это обусловлено тем, что обученная нейронная сеть будет использоваться в качестве модели объекта для настройки параметров регулятора. В этом случае она будет функционировать в автономном режиме, и данные с выхода реального объекта будут недоступны, т.е. возможна только параллельная схема. Входной вектор при этом формируется на каждом шаге и, следовательно, значение параметра batch size при тестировании может быть равно только 1. Были исследованы нейронные сети с различными функциями активации: linear, relu, selu, sigmoid, tanh.

Для тестирования использовалась переходная характеристика объекта управления, т.е. значения на входе объекта всегда равны 1. Таким образом, тестирующая выборка кардинально отличается от обучающей, что гарантирует достоверность тестирования и позволяет избежать эффекта переобучения.

На рис. 4 и рис. 5 показаны результаты с функциями активации *selu* и *elu* при тестировании как по последовательно-параллельной, так и по параллельной схеме. При этом следует упомянуть о том, что современные реализации TensorFlow и Keras сами осуществляют масштабирование данных, поэтому все функции активации можно использовать при различных знаках и значениях по модулю входных и выходных данных.

Рис. 4. Функция активации *selu*Рис. 5. Функция активации *elu*

На рисунках «линиями» обозначены значения выхода нейронной сети при последовательно-параллельной схеме тестирования, а значками «x» — значения выхода нейронной сети при параллельной схеме тестирования.

Кроме того, следует отметить, что достаточно близкие значения на выходе объекта как при последовательно-параллельной, так и параллельной схеме тестирования, говорят о том, что нейронная сеть была достаточно хорошо обучена.

То, что во всех случаях имеется ошибка в установившемся режиме, никак не сказывается на качестве полученной имитационной модели, так как эта ошибка при использовании данной модели для настройки регулятора будет скомпенсирована интегрирующим звеном в обратной связи. Главным критерием оценки качества модели является её динамика, точнее насколько точно она соответствует динамике реального объекта. С этой точки зрения также наилучшие результаты демонстрирует функция активации «*elu*».

В дальнейшем следует определить нижние границы количества нейронов в скрытых слоях и само количество скрытых слоёв, при которых будут достигаться устойчиво повторяющиеся удовлетворительные показатели качества переходных процессов.

Выводы

Исследование последовательных методов параметрической идентификации динамических процессов с помощью нейронных сетей показали:

– биективная идентификация с помощью двух последовательно обучаемых нейронных сетей, которые объединяются с помощью резервуара синаптических коэффициентов первой нейронной сети, позволяет значительно упростить процедуру определения типов и структуры нейронных сетей и их обучение. Это указывает на перспективность данного метода для идентификации на основе экспериментальных данных параметров различных динамических процессов и объектов;

– идентификация нелинейного объекта благодаря разделению модели на линейную и нелинейную части позволяет существенно упростить процедуру определения параметров объекта с приемлемой точностью. Данный метод перспективен для применения в адаптивных системах управления, когда необходимо оперативно изменять настройки регуляторов при изменении параметров объекта управления.

Результаты экспериментов доказали эффективность и перспективность рассмотренных методов, в связи с чем необходимо их дальнейшее развитие в следующих направлениях:

– для биективного метода необходима его модификация с целью объединения резервуара и идентифицирующей нейронной сети;

– расширение метода имитационной идентификации на динамические объекты с нелинейностями первого и третьего типов (выражения (1) и (3)).

Список литературы

1. Осовский С. Нейронные сети для обработки информации. Москва : Финансы и статистика. 2002. 344 с.
2. Хайкин С. Нейронные сети: полный курс, 2-е издание / пер. с англ. Москва : ИД «Вильямс». 2008. 1104 с.
3. Charu C. Aggarwal. Neural Networks and Deep Learning. Springer Cham. 2018. 497 p.
4. Narendra K.S., Parthasarathy K. Identification and control of dynamical systems using neural networks // IEEE Transactions on Neural Networks. 1990. V. 1, N 1. P. 4–27.
5. Терехов С.А. Гениальные комитеты умных машин // Научная сессия МИФИ-2007. IX Всероссийская научно-техническая конференция «Нейроинформатика-2007». Лекции по нейроинформатике. Ч. 2. Москва : МИФИ. 2007. С. 11–42.
6. Староверов Б.А., Гнатюк Б.А. Формирование ансамбля нейронных сетей как основы инвариантной системы прогнозирования (на примере

- электропотребления) // XVIII Всероссийская научно-техническая конференция «Нейроинформатика-2016»: сборник научных трудов. Ч.1. Москва : НИЯУ МИФИ. 2016. С. 193–203.
7. Staroverov B.A., Gnatyuk B.A. Universal energy consumption forecasting system based on neural network ensemble // Optical Memory and Neural Networks. 2016. V. 25, N 3. P. 198–202.
 8. Лебедева Т.В. Анализ временных рядов и бизнес-прогнозирование: учебно-методическое пособие. Оренбург: ОГУ, 2018. 240 с.
 9. Дуброва Т.А. Статистические методы прогнозирования в экономике. Москва : Московский международный институт эконометрики, информатики, финансов и права, 2004. 60 с.
 10. An End-to-end Open Source Machine Learning Platform // [Online]. <https://www.tensorflow.org/>.
 11. Keras. Simple. Flexible. Powerful. [Online]. <https://keras.io/>.
 12. Semenov A.D., Volkov A.V., Shchipakina, N.I. Operational control algorithm of parameters of high-pressure sodium lamps based on a statistical time series model // IOP Conference Series: Materials Science and Engineering. 2020. 971(3), 032084.
 13. Volkov A.V., Semenov A.D., Staroverov B.A. The Reiterated Neural Network Parametric Identification of Nonlinear Dynamic Models of Objects // Advances in Automation III, International Russian Automation Conference, RusAutoCon. 2021, P. 34–42.
 14. Schrauwen B., Verstraeten D., Campenhout J.V. An overview of reservoir computing theory, applications and implementations // Proc. of the 15th European Symp. On Artificial Neural Networks. 2007. P. 471–482.
 15. Бендерская Е.Н., Никитин К.В. Рекуррентная нейронная сеть как динамическая система и подходы к ее обучению // Научно-технические ведомости СПбГПУ 4' (176). 2013. Информатика. Телекоммуникации. Управление.
 16. Maass W., Natschläger T., Markram H. Real-time computing without stable states: a new framework for neural computations based on perturbations // Neural Computation. 2002. V. 11. P. 2531–2560.
 17. Astrom K.J. Computer-Controlled Systems – Theory and Design. Prentice Hall. 1997. 557 p.

E.M. SYSOYKIN, I.D. SHPAK, A.I. ANTONOV

Bauman Moscow State Technical University, Moscow, Russia
egor.sysoykin@mail.ru, shid18u875@student.bmstu.ru

COMPETITION NUMBER RECOGNITION USING AN ENSEMBLE OF DEEP LEARNING MODELS

The article deals with the problem of recognizing competition numbers of sports participants on images. A method for solving this problem has been proposed. It uses an algorithm that contains four steps: detection of a region of interest, detection of a polygon containing a number, recognition of numbers on the found areas and the integration of the results. An implementation based on the one-step detector YOLOv5 has been developed. The advantage of YOLO is the availability of tools to train the model on one's own data and its high speed of inference. For model training have been prepared datasets which are based on open data. The results of trained models are also presented in this paper.

Keywords: *object detection, OCR, one-stage detector, YOLOv5.*

Introduction

Modern neural networks are widely used in the field of object recognition in images [1]. One of the areas in which the use of object detectors can be useful is the organization of sports events, where automatic recognition of the competition numbers of participants will allow indexing the created media data, as well as easing the task of judging.

The task of competition number recognition is similar to the popular task of license plate recognition, for which various solutions based on neural networks of CNN type, are used [2][3].

Since we are considering the task of number recognition, i.e., not only its detection but obtaining a text representation, we can assume that it can be solved by ready-to-use OCR systems. To test this supposition, Tesseract – popular OCR system developed by Google was used, but in the process of its testing it was not possible to obtain any acceptable results. For example, when recognizing the competition number on motorcycles, Tesseract is not able to provide any result at all in a large number of cases, which is consistent with the results of other studies [4].

In order to understand the reasons for such results it is necessary to examine how text recognition occurs in OCR systems. This process involves a stage of detection, that is, the selection of the region of interest (ROI) - part of the image

containing the text, which is followed directly by the recognition of the text within this area. Tesseract is designed for text recognition in documents and performs a stage of detection by using mathematical transformations of the original image, and shows itself well for the detection of text on a static background [5], but is not suitable for the considered task. For the phase of text recognition Tesseract uses a neural network of type LSTM, which shows pretty high accuracy when applied to a pre-selected area of interest, and truly recognizes about 50-60% of the given numbers. It is likely that the accuracy can be significantly improved by the training of a neural network to solve the detection task on a specialized dataset, which contains data from the considered subject area.

Thus, we can conclude that the main problem in competition number recognition is the detection part. As a basic model for the detection and recognition tasks was taken YOLO, which is designed to detect objects on images and videos in real time [6]. The lightweight nature of YOLO also allows users to perform training on highly-available equipment.

Object detection using YOLO

YOLOv5s, which is a slightly lighter version of YOLOv5, was used to develop the test solution. YOLO (acronym for You Only Look Once) is a One-Stage detector. This approach assumes predicting the bounding boxes of recognized objects and determining their classes in one pass of the input data through the neural network. The output of YOLO is one or more detected objects, i.e., a combination of bounding box, the confidence of object existence inside this bounding box, and specific class probabilities for this object.

The architecture of YOLO is shown in fig. 1 and it contains three main parts: backbone, neck and head. The YOLOv5 backbone is based on the CSPDarknet53, which is a convolutional CNN neural network containing 53 layers, with modifications such as Spatial-Pyramid-Pooling [7], which allows using images of different formats without having to compress or crop them before passing to model, and Cross-Stage-Partial-connections [8], which allows accelerating the model while maintaining accuracy. The main task of the backbone is to extract feature maps from the original image.

The output data from the backbone is transferred to the next layer, called neck. In YOLOv5 it is based on PANet [9], which upsamples and concatenates the resulting feature maps, using data propagation from the lower layers to the upper layers with shortened paths that contains about 10 layers. In this way, more information about the original image is preserved, which leads to more accurate detection of small objects.




Fig. 1. Architecture of YOLOv5

The last part is the head, which applies convolutional filters to the data obtained from the neck and gives final information about the objects found. The specific feature of YOLOv5 in this stage is the application of different filters to three scales of feature maps, i.e., the detection of objects is performed with different detalization and after those obtained results are combined. YOLOv5 uses the previously mentioned format as the output data format for each object found.

Recognition model ensemble

It was decided to use an ensemble of neural networks as a model architecture. This approach allows us to divide the problem solution into separate stages. To create a program solution, it is necessary to collect and process datasets for each stage and train models on them. As a disadvantage, there is no connection between different neural networks because models are trained separately.

The considered task was divided into the following stages:

Detection of a region of interest. The task of this step is to detect an area on the image, which contains a competition number. To describe the found region, the x and y coordinates of the center, as well as its height h and width w are used, which corresponds to the format of the output data used by YOLO. The Average Precision (AP) metric is proposed to evaluate the quality of this step. AP is the value of the area under the Precision-Recall curve which is calculated at certain values of Intersection over Union (IoU). Intersection over Union describe the extent of overlap of two boxes and is evaluated as (1).

$$IoU = \frac{S_{overlapp}}{S_{union}}. \quad (1)$$

YOLO provides two metrics based on AP, namely AP₅₀, i.e., AP at IoU equal to 0.5 and mAP_{50:95}, which is calculated as (2)

$$mAP_{50:95} = \frac{1}{10} \sum_{i=50}^{i=95} AP_i; i = 50, 55, 60 \dots 95. \quad (2)$$

It is worth noting that the model at this stage deals with the detection of objects belonging to the same class, that means that there are no errors associated with the incorrect definition of the object class.

Polygon detection. Receiving as input data previously detected ROI, the task of this stage is to identify the four coordinates in which exactly fits the number. That is, the previous stage can be called a rough detection of ROI, while the task of this stage is to refine it. At the end of this stage the alignment of the slope of the obtained area with the number by means of matrix perspective transformation is performed, which shall ease the task of recognizing the digits in the number. For software implementation of this stage, we used a modification of the YOLO's head, the meaning of which is to change the format of the bounding box to the coordinates of the four points bounding the polygon. The evaluation of this stage can be performed using the metrics listed above, because the performed task is similar to the task of the previous stage.

Numerical number recognition on the polygon and on the area of interest. This stage recognizes directly the digits within the area containing the competition number and merges them into a single numerical representation of number, by using the leftmost borders of the found bounding boxes, i.e., merges the digits from left to right. Since each recognized digit represents a separate class, there appear errors related to correct class assignment, which should be taken into account for calculating the metrics. To assess this stage, it is proposed to consider the results of training. Another important point is that for this stage it

is not important to precisely define the area containing the number, so the AP_50 and AP_50:95 metrics used in the previous stages do not represent the real accuracy of the model. Instead, we will use Precision and Recall presented at IoU of 0,45.

Selection of the best result. The results of the previous stage are two text representations of numbers recognized on the polygon and the region of interest. The task of the final stage is to compare given results and choose the best among them. Any suitable algorithm can be used for this purpose. At the moment, the edges of the area with the number can be incorrectly clipped by the model with a polygon, so that some information is lost. On the other hand, recognition on an aligned polygon is more likely to be accurate. The future choice for the final implementation must take into account the specifics of the input data and the quality of the models used for the previous stages.

Fig. 2 represents described stages in whole algorithm.




Fig. 2. Algorithm for competition number recognition

Dataset preparation

The model training task requires the preparation of three different datasets for training:

1. ROI detection model
2. Polygon detection model
3. Number recognition model

Since there are no ready-made datasets for the task of number recognition of motorcycle competition participants in the public domain, it was decided to collect the data for training by ourselves. The initial set of photos was taken from the open access social network VK. As an initial dataset, 18891 raw photos from motorcycle competitions were downloaded.

After obtaining the raw data, it was processed, and was generated a dataset to train the first model, consisting of 1400 photos.

The next process is the labeling of the numbers. It is necessary to select the area on all the photos that contains the number and present the text file in YOLOv5 notation. The online marker from Roboflow [10] was used for this purpose.

The datasets for training the recognition model and the polygon detection model are generated by applying a model trained to detect the region of interest to the original images. In the data labeling process, the VGG Image Annotator tool was used for the polygon detection model whose output was then converted to the YoloV5 format, for which 1200 images were labeled.

For the last model performing the number recognition, 10000 images were labeled, which makes this dataset the largest of the selected ones. This dataset contains images of regions of interest where bounding boxes for each separate digit are allocated.

Model training results

All models were trained using described datasets using Nvidia GTX 1050 Ti 4Gb GPU. The collected data on the performance of the 1st model is shown in fig. 3.

According to the obtained graphs we can conclude that the model is able to find the area where the number is located, however, the value of AP_{50:95} metric equal to 0,56 suggests that the bounding box predicted by the model does not fully correspond to the true ground bounding box. Overall, the metrics obtained for this model can be considered to be satisfactory.




Fig. 3. Precision (at IoU=0,45), recall (IoU=0,45), mAP_{0.5} и mAP_{0.5:0.95} for ROI detection model

For the polygon model, the collected data are presented in Table 1. It is worth noting that due to high complexity of the polygon detection task, the learning process is much slower than for the 1st model and requires an increase in the number of epochs. According to the results of 350 epochs of training, the model has lower precision compared to the 1st model, but higher recall. While for the previous model the metrics values can be considered satisfactory due to

the fact that the detection task is performed on the entire input image, for this model such metrics values are not acceptable, and this model requires post-training with an extended dataset and a larger number of epochs.

The last model took 650 epochs to train. The metrics obtained in the course of training are presented in the table 1. The obtained value of AP_50:95 metric is equal to 0,63, which is slightly higher than in previous models. However, more important for this model are precision and recall which equals to 0,944 and 0,927. This means high cognitive ability of the model. In addition, as can be seen from the matrix in Fig. 4 all classes have been trained evenly, and are correctly recognized more than 86% of the time, but there is overtraining for class "1", because there are a large number of background FP cases, that is, the model predicts objects of this class where they do not actually exist.

Table 1

Evaluated model metrics

Model stage	Precision (IoU = 0,45)	Recall (IoU = 0,45)	AP_50	mAP_50:95
ROI detection	0,8657	0,8507	0,9199	0,5559
Polygon detection	0,79032	0,9245	0,9468	0,5962
Number recognition	0,9440	0,9269	0,9574	0,6413




Fig. 4. Confusion matrix for recognition model

Conclusion

The results of the individual trained models, allow us to apply them to the problem at hand, even in spite of the relatively small training datasets. In further research, it is necessary to further train the models, as well as to evaluate the effectiveness of the algorithm that uses them, and to choose a way to combine the results for the last stage of the model.

References

1. Krizhevsky A., Sutskever I., Hinton G. ImageNet classification with deep convolutional neural networks // In Proceedings of the 25th International Conference on Neural Information Processing Systems. (NIPS'12). Curran Associates Inc., Red Hook, NY, USA. 2012. P. 1097–1105.
2. Wang S., Shih H., Shen Z., Tai W. End-to-End High Accuracy License Plate Recognition Based on Depthwise Separable Convolution Networks (2022). <https://arxiv.org/pdf/2202.10277.pdf>, last accessed 2022/4/18.
3. Zandi M., Rajabi R. Deep Learning Based Framework for Iranian License Plate Detection and Recognition. 2022. <https://arxiv.org/pdf/2201.06825.pdf>, last accessed 2022/4/22.
4. Velarde M., Velarde G. Benchmarking Algorithms for Automatic License Plate Recognition. 2022. <https://arxiv.org/pdf/2203.14298.pdf>, last accessed 2022/4/30.
5. Zacharias E., Teuchler M., Bernier B. Image Processing Based Scene-Text Detection and Recognition with Tesseract. 2020. <https://arxiv.org/pdf/2004.08079.pdf>, last accessed 2022/3/10.
6. Bochkovski A., Wang C., Liao H. YOLOv4: Optimal Speed and Accuracy of Object Detection. 2020. <https://arxiv.org/pdf/2004.10934.pdf>, last accessed 2022/5/15.
7. He K., Zhang X., Ren S., Sun J. Spatial Pyramid Pooling in Deep Convolutional Networks for Visual Recognition. 2015. <https://arxiv.org/pdf/1406.4729v4.pdf>, last accessed 2022/4/30.
8. Wang C., Liao H., Yeh I., Wu Y., Chen P., Hsieh J. CSPNet: A New Backbone that can Enhance Learning Capability of CNN. 2019. <https://arxiv.org/pdf/1911.11929.pdf>, last accessed 2022/5/13.
9. Liu S., Qi L., Qin H., Jia J. Path Aggregation Network for Instance Segmentation 2018. <https://arxiv.org/pdf/1803.01534v4.pdf>, last accessed 2022/5/13.
10. Roboflow website, <https://app.roboflow.com>, last accessed 2022/5/13.

Л.С. ЧЕРНЫШЕВООО «Матсофт»
math4soft@yandex.ru**ПРОГНОЗИРОВАНИЕ ЗНАЧЕНИЙ ВРЕМЕННОГО РЯДА
С ПОМОЩЬЮ НЕЙРОННОЙ СЕТИ ПРИ РЕШЕНИИ
ЗАДАЧИ ДИНАМИЧЕСКОГО ЦЕНООБРАЗОВАНИЯ***

В работе приведен пример прогнозирования значений смоделированного временного ряда, построенного по аналогии с временными рядами ежесуточного количества покупок товаров на маркетплейсе, с помощью специально разработанной для этих целей нейронной сети. Полученный прогноз послужит основой для построения модели динамического ценообразования. Выполнено сравнение полученного прогноза с результатом работы стандартной модели прогнозирования временных рядов – интегрированной модели авторегрессии скользящего среднего (ARIMA), реализация которой взята из стандартной библиотеки python.

Ключевые слова: *нейросеть, временной ряд, прогноз, авторегрессия, скользящее среднее.*

Введение

Для создания оптимальных алгоритмов динамического ценообразования на обращающиеся в свободном рынке товары, приводящие к увеличению получаемой покупателем-продавцом прибыли, в математической экономике используется теория двойственности в задачах линейного программирования. В работах по использованию математического аппарата для построения моделей потребления [1–4] предложен непараметрический метод анализа потребительского поведения, основанный на проверке гипотезы о рациональности поведения и решении обратной задачи – восстановлении функции полезности по временным рядам цен и объемов покупок товаров. Сегментация рынка потребительских товаров и услуг формально описывается деревом экономических индексов, построение которого осуществляется с помощью непараметрического метода, предложенного в работах С. Африата (1973) и М. Хаутмана (1995) и сводится к проверке гипотезы о рациональности поведения потребителя.

* Данная работа выполнена в рамках договора гранта от Фонда содействия инновациям 122ГСИИИС12-D7/76682 от 09.06.2022

В то же время для улучшения качества восстановления функции полезности крайне актуальной является построение максимально точного прогноза на различные горизонты основных управляющих параметров, а именно, цен и объемов покупок товаров по имеющимся временным рядам изменений этих характеристик в прошедшие периоды. В совокупности описанные подходы позволят предприятию-продавцу производить динамическое управление ценой своего товара с целью получения максимальной прибыли на различных временных горизонтах.

В настоящей работе показан пример прогнозирования временного ряда с помощью специально разработанной для этих целей нейронной сети. В качестве прогнозируемого временного ряда использовался ряд, сгенерированный модельной функцией, по своим характеристикам соответствующей естественным эконометрическим рядам, в настоящем примере рядам данных по количеству ежедневных продаж товара на маркетплейсе, включающих полиномиальную динамику, периодичность и шум. В работе выполнено сравнение полученного прогноза с результатом работы стандартной модели прогнозирования временных рядов – интегрированной модели авторегрессии скользящего среднего (ARIMA), реализация которой взята из стандартной библиотеки `statsmodels` языка программирования `python`.

Задача прогнозирования товарного спроса и эластичности его по цене на различных временных горизонтах может сводиться к задаче экстраполяции временных рядов ежедневных продаж при различных фиксированных уровнях цен, чтобы построить поля распределений функций спроса от цены в различные моменты времени. Для построения прогноза спроса на товар может использоваться байесовский вероятностный подход [6], при котором модель спроса используется для формирования прогноза на основе исторических транзакционных данных – данных о продажах товара, включающих цену, количество, а также сопутствующих продаже условиях – времени года, наличия праздников, распродажи и прочее. Данные преобразуются в вероятностное распределение прогноза с параметрами цены, наличия акций, сезонности и времени. В общем случае среднее значение функции распределения вероятностей является прогнозом. Верхняя и нижняя границы прогноза, т.е. стандартное отклонение, определяют доверительный интервал. Чем уже разрыв между верхней и нижней границами прогноза, тем меньше доверительный интервал (большая уверенность в прогнозе). Прогноз определяется с помощью оценки максимального правдоподобия, предполагающей стандартную модель шума Пуассона. Затем определяется ковариационная матрица, которая фикси-

рует дисперсию каждого параметра модели, а также ковариацию между параметрами модели. Ковариационная матрица также используется для определения доверительного интервала вокруг прогнозов, полученных на основе модели. Данный вероятностный подход будет тем успешнее работать, чем точнее удастся построить экстраполяции имеющихся рядов данных на требуемые временные горизонты. Распространенные параметрические способы экстраполяции временных рядов [5] – степенная и полиномиальная регрессии – обладают недостатком, заключающимся в возможности возникновения неконтролируемой ошибки на интервале прогнозирования, особенно при высоком порядке прогнозирующей функции. Методы прогноза, основанные на идеях декомпозиции процессов по эмпирическим модам, например [7], использовании тригонометрических многочленов и вейвлетов не обеспечивают достаточной точности при росте числа составляющих процесса, т.е. роста количества влияющих переменных. Методы прогноза с использованием базисных функций (радиальные, «цилиндрические» и «эллиптические») менее чувствительны к росту размерности функции. Большое распространение получило прогнозирование временных рядов моделями авторегрессии скользящего среднего. Однако использование этих моделей часто может приводить к нелинейному росту ошибки уже при удалении на несколько шагов вперед.

Постановка задачи и описание алгоритма

Целью настоящей работы было сравнить точность прогнозирования модельного временного ряда, по своим характеристикам напоминающего временной ряд, числа продаж товара на маркетплейсе, проведенного с использованием разработанной искусственной нейронной сети и стандартной модели прогнозирования временных рядов – интегрированной модели авторегрессии скользящего среднего (ARIMA), реализация которой взята из стандартной библиотеки `pytho`n. Используемая в работе нейросеть представляла собой стандартную полносвязную сеть прямого распространения [9], состоящую из трех слоев: входного слоя длиной K нейронов, скрытого слоя длиной G нейронов и одного нейрона выходного слоя. Под искусственным нейроном понимается конструкция, состоящая из сумматора входных сигналов от нейронов предыдущего слоя или сигналов входа (для нейронов входного слоя), передающий суммированный сигнал через функцию активации, представляющую собой гиперболический тангенс для нейронов скрытого и выходного слоев и константу, равную единице для нейронов входного слоя. Переход выходных сигналов с нейронов одного слоя на нейроны следующего слоя происходит через

синаптические связи между нейронами соседних слоев, которые на практике реализуются путём умножения выходного сигнала с i -го нейрона, направленного на k -й нейрон следующего слоя, на коэффициент синаптической связи $b_{i,k}$. Выходной сигнал второго (скрытого) слоя записывается в виде

$$y_t^1 = \begin{pmatrix} y_{1,t}^1 \\ \dots \\ y_{G,t}^1 \end{pmatrix} = \begin{pmatrix} \varphi(b_{1,1}^T \cdot X_t + b_{0,1}) \\ \dots \\ \varphi(b_{1,G}^T \cdot X_t + b_{0,G}) \end{pmatrix}, \quad (1)$$

где φ – функция активации гиперболический тангенс, $X_t = [X_t^1, \dots, X_t^K]$ – входной сигнал – обучающая выборка со временем смещения t , b_1 – матрица синаптических связей скрытого слоя, b_0 – вектор весов смещения скрытого слоя:

$$\begin{pmatrix} b_{1,1} \\ \dots \\ b_{1,G} \end{pmatrix} = \begin{pmatrix} b_{1,1}^1 \dots b_{K,1}^1 \\ \dots \\ b_{1,1}^1 \dots b_{K,G}^1 \end{pmatrix}, b_0 = [b_{0,1}, \dots, b_{0,G}].$$

Выходной сигнал третьего слоя (единственного нейрона выходного слоя) будет являться итоговым сигналом выхода нейросети и записывается в виде

$$y_{2,t} = (\varphi(b_{2,1}^T \cdot y_t^1 + b_{2,0})), \quad (2)$$

где φ – функция активации гиперболический тангенс, $b_{2,1} = [b_{2,1}^1, \dots, b_{2,1}^G]$, $b_{2,0} = \text{const}$.

Входной сигнал $X_t = [X_t^1, \dots, X_t^K]$ используемой нейросети представляет собой начальный отрезок временного ряда длиной K , каждый элемент которого подавался на вход соответствующего из K нейронов входного слоя. Выходным сигналом нейросети при идеальном обучении должен был стать $(K+1)$ -й элемент исходного временного ряда. Таким образом, ошибка обучения сети на шаге t :

$$e_{2,t} = y_{2,t} - X_t^{K+1} \quad (3)$$

составляла разницу между значением выходного сигнала и $(K+1)$ -м элементом исходного ряда. Обучение нейросети проводилось методом об-

ратного распространения, в котором полученная ошибка транслировалась обратно по слоям нейросети, при этом методом градиентного спуска рассчитывались поправочные слагаемые для корректировки синаптических весов нейронов каждого слоя сети, а также нейронов смещения. После корректировки весовых синаптических коэффициентов строился новый входной сигнал путем сдвига отрезка временного ряда, подающегося на K нейронов входного слоя на 1 шаг по шкале времени. Причем на место K -го значения входного сигнала вставало не значение исходного временного ряда, а выходное значение нейросети на предыдущем шаге. Затем снова производилась процедура прямого распространения и заново рассчитывалась «ошибка обучения сети» как разница выходного значения и значения $(K + 2)$ -го элемента исходного временного ряда. И снова повторялась процедура обратного распространения и корректировки синаптических весов нейросети. И так i раз, до тех пор, пока значение $i + K$ не достигало бы значения конца периода обучения. Тогда эпоха обучения считалась законченной, значение i снова принималось равным нулю и обучение вновь повторялось. В виде входного сигнала брались значения приращений исходного ряда. Полученные значения приращений в свою очередь также нормировались, чтобы не выходить за пределы диапазона $(-1,1)$.

Для сравнения эффективности нейросетевого подхода и подхода, основанного на классической модели авторегрессии скользящего среднего, использовался сгенерированный ряд, включающий в себя линейный тренд, отвечающий за рост охвата целевой аудитории маркетингом, нелинейное нарастание спроса на товар за счет роста его узнаваемости и популярности, сезонный цикл, высокочастотную компоненту распределения активности покупателей внутри дней недели и шумовую компоненту.

Включающая в себя все перечисленные факторы функция может иметь вид

$$Y(i) = \sin(x(i))/2 + \sin(x(i)/10) \cdot 5 + 0,5 - 0,03 \cdot x(i) + 2/1000 \cdot x(i)^{1,9} + \text{randint}(1,99)/50.$$

Значения данной функции рассчитывались на отрезке $i = 0 \dots 490$, что позволяло (приняв за единицу дискретности 1 сутки) провести обучение ($L = 320$) имитации годового отрезка времени и верификацию ($F = 170$) – почти на полугодовом отрезке. Для данной функции на выбранном диапазоне изменения x (0, 490) нормировочный множитель, используемый для нормировки значений приращений, было достаточно выбрать равным 0,1, чтобы обеспечить нахождение всех значений разностей в пределах от-

резка $(-1,1)$. Для такого диапазона длины ряда параметр длины скользящего окна K – было решено выбрать равным 80. Число нейронов G составляло 90. Важным моментом было проведение предварительной свертки исходного ряда для уменьшения затрат машинного времени на обучение. Для этого исходный ряд делился на отрезки длиной U интервалов дискретности ряда. Свертку предполагалось проводить 3-мя способами – с использованием функции softmax на периоде свертки, взятия среднего значения на этом периоде, либо учет данных только на концах отрезка свертки. В настоящей работе использовался 3-й вариант. Так, при свертке ряда в два раза машинное время, затрачиваемое на прохождение 50 эпох, составляло порядка двух минут.

Результаты


Параметром скорости обучения является константа SPEED, значение которой задается произвольно из диапазона $(0,1)$. Для нашей дискретности оптимальным параметром SPEED оказались значения 0,001–0,002. Увеличение скорости обучения до 0,16 за пределы указанного диапазона приводило к неустойчивости и переобучению нейросети с ухудшением точности соответствия модели на участке обучения, тем не менее на участке валидации точность прогноза случайным образом улучшилась. Таблица точности прогноза на участке валидации, число эпох и значения константы SPEED приведены в табл. 1. График данной функции и кривые прогноза в динамике обучения приведены на рис. 1(а, б, в, г), где оранжевый участок является областью обучения $x(i) = 80 \dots 320$, а синий $x(i) = 321 \dots 490$ область валидации прогноза. Критерием точности прогноза служило значение MSE – средняя сумма квадрата разности значений прогноза и исходного ряда на отрезке валидации.

Таблица 1


Результаты обучения нейросети

Число эпох обучения	SPEED	Средний квадрат ошибки MSE
50	0,001	162,219
100	0,001	156,585
150	0,001	153,671
200	0,001	152,057


250	0,001	149,918
300	0,001	144,277
350	0,001	128,238
400	0,001	81,521
450	0,001	43,619
500	0,001	36,149
550	0,001	34,117
600	0,001	32,827
650	0,004	23,656
700	0,016	2,867




а) начало обучения




б) 200 эпох обучения




в) 350 эпох обучения



г) 450 эпох обучения



д) 600 эпох обучения



е) 700 эпох обучения

Рис. 1. Кривые прогноза в динамике обучения

Перейдем теперь к сравнению с результатами прогноза интегрированным методом авторегрессии скользящего среднего ARIMA [8]. Аналогичная модельная функция

$$Y(i) = \sin(x(i))/2 + \sin(x(i))/10 \cdot 5 + 0,5 - 0,03 \cdot x(i) + 2/1000 \cdot x(i)^{1,9} + \text{randint}(1,99)/50$$

использовалась для построения прогноза при помощи стандартной модели прогнозирования временных рядов – интегрированной модели авторегрессии скользящего среднего – ARIMA(p, q, d), где отличие от модели ARIMA(p, q), записывающейся в виде

$$Y_t = \sum_{i=1}^p \alpha_i Y_{t-i} + \sum_{j=1}^q \beta_j \varepsilon_{t-j} + \varepsilon_t, \quad (4)$$

где ε_t – белый шум, состоит во взятии разностей порядка d для исключения нестационарности ряда:

$$\Delta^d Y_t = \sum_{i=1}^p \alpha_i \Delta^d Y_{t-i} + \sum_{j=1}^q \beta_j \varepsilon_{t-j} + \varepsilon_t, \quad (5)$$

где p – порядок авторегрессии, q – порядок модели скользящего среднего, d – порядок взятия разностей. Вычисление прогноза по модели ARIMA(p, q, d) проводилось с использованием модуля стандартной библиотеки statmodels языка python.

Перед расчетом параметров модели строились графики исходного ряда, первых разностей исходного ряда, вторых разностей исходного ряда, а также их автокорреляционные и частичные автокорреляционные функции (см. рис. 2).




Рис. 2. Графики исходного ряда, первых разностей исходного ряда, вторых разностей исходного ряда. Автокорреляционные и частичные автокорреляционные функции

Затем определялись значения параметров модели ARIMA и строился прогноз. Точность прогноза оценивалась на отрезке валидации как: MSE – средняя сумма квадрата разности значений прогноза и исходного ряда.

Лучший результат получился для модели ARIMA(5,3,2) – MSE = 9,973 (см. рис. 3а). Для модели ARIMA (6,4,2) – MSE = 59,228 (см. рис.3б).




Рис. 3. Результаты для модели ARIMA(5,3,2) и ARIMA (6,4,2)

Выводы

Полученные результаты показывают, что прогноз смоделированного временного ряда числа суточных продаж в течение условных 1,5 лет, построенный с помощью разработанной ИНС, является достаточно эффективным. Построенная нейронная сеть может использоваться для прогнозирования эконометрических временных рядов на горизонтах порядка 50% от длины участка обучения, т.е. для данного временного ряда оказалось возможным построение прогноза с точностью порядка 30% на горизонте 3–4 месяца. Использование модели ARIMA из готового модуля Statmodels, являющегося библиотекой языка python значительно хуже результатов точности прогноза, построенного с помощью разработанной искусственной нейронной сети для данного типа модельного ряда и соотношения длин отрезков прогноза и обучения.

Выводом является эффективность применения разработанной ИНС для прогноза эконометрических временных рядов на горизонтах порядка вплоть до 50% от длины участка обучения. Точность полученного прогноза гораздо выше по сравнению с моделью ARIMA, что делает ценным использование разработанной ИНС для прогнозирования рядов эконометрических характеристик, а также последующее использование этих прогнозов в построении оптимальных алгоритмов динамического ценообразования.

Список литературы

1. Обен Ж-П., Экланд И. Прикладной нелинейный анализ. Москва : Мир. 1988. 510 с.
2. Шананин А.А., Автухович Э.В., Кукушкин Н.С., Обросова Н.К., Петров А.А., Поспелов И.Г., Поспелова Л.Я., Чуканов С.В. Агрегирование микроэкономических описаний и исследование возникающих обратных задач // Отчет о НИР № 96-01-00664 (Российский фонд фундаментальных исследований).
3. Обросова Н.К. Анализ устойчивости рыночных механизмов в модели ценообразования вальрасовского типа с запаздываниями // Тезисы докладов XXXIII научной конференции факультета физико-математических и естественных наук. 1997. С. 72.
4. Шананин А.А. Проблема интегрируемости и непараметрический метод анализа потребительского спроса // Труды МФТИ. 2009. Т. 1, N 4. С. 84–98.
5. Чернышев Л.С. Способ и система для прогнозирования значений временного ряда с использованием искусственной нейронной сети. Патент. [RU2019128366A](#) 2019-09-10.
6. May B. et al. System and method of using demand model to generate forecast and confidence interval for control of commerce system. Current Assignee SAP SE. [US8117061B2](#) 2012-02-14.

7. Белов А.А., Ермолаев В.А., Кропотов Ю.А., Проскуряков А.Ю. Способ нейросетевого прогнозирования изменения значений функции с её предварительной вейвлет-обработкой и устройство его осуществления // Патент России № 2600099. 2016.
8. Бокс Дж., Дженкинс Г. Анализ временных рядов. Прогноз и управление. Москва : Мир, 1974. Вып. 1. 288 с.; Вып. 2. 254 с.
9. Хайкин С. Нейронные сети: полный курс. Москва : Издательский дом «Вильямс», 2006. 1104 с.

З.М. ШИБЗУХОВ

Институт математики и информатики
Московского педагогического государственного университета
Московский физико-технический институт
(национальный исследовательский университет)
intellimath@mail.ru

**ОБ ОДНОМ ОБОБЩЕННОМ НЕЙРОСЕТЕВОМ МЕТОДЕ
КЛАСТЕРНОЙ РЕГРЕССИИ**

Предлагается подход к построению кластерной регрессии на основе принципа минимизации дифференцируемых усредняющих агрегирующих функций от потерь, малочувствительных к выбросам. Предлагается алгоритм типа итеративного перевзвешивания для поиска оптимальных значений параметров регрессионных моделей. На наглядных примерах показывается устойчивость к выбросам предложенного подхода и алгоритма.

Ключевые слова: *нейросетевая модель, задача регрессии, робастная оценка среднего, метод итеративного перевзвешивания.*

Введение

В настоящей работе рассматривается задача поиска оптимальных параметров нескольких регрессионной моделей, которые могут одновременно иметь место в анализируемых данных. Это может быть связано с тем, что анализируемые данные могут содержать в себе информацию о нескольких процессах или ситуациях. Такая задача, например, может возникать, когда данные могут быть разбиты на несколько кластеров, которые сосредотачиваются вокруг своих регрессионных зависимостей [1–4].




Рис. 1. Примеры задач

Два типичных примера, иллюстрирующих существования нескольких линейных зависимостей, представлены на рис. 1. Первый связан с восприятием тонов в музыке и возникновением обертонов (tonedata) [5]. Второй представляют зависимость уровня престижности автомобиля, приобретаемого представителями различных профессий, от уровня их дохода. (duncan) [6].

Классическая постановка задачи

Задан набор данных: $\{x_1, \dots, x_N\} \subset R^n$ – набор векторов входов, $\{y_1, \dots, y_N\} \subset R$ – набор значений, ожидаемых на выходе. Предполагаем, что зависимости $y_1 = f_1(x), \dots, y_q = f_q(x)$ представлены в виде нейросети, которая реализует преобразование

$$y = (y_1, \dots, y_q) = f(x; w) = (f_1(x; w), \dots, f_q(x; w)),$$

где w – блок параметров нейросети, $f_j(x; w)$ – функциональная композиция нейронов, участвующих в вычислении j -го выхода.

Простейший пример – однослойная сеть из q линейных нейронов для идентификации q линейных зависимостей:

$$y_j = \theta_j + w_j \cdot x, j = 1, \dots, q,$$

где $w_j \in R^n$, $w_j \cdot x$ – скалярное произведение; например, для идентификации q линейных фрагментов на плоскости или плоских фрагментов в пространстве.

Более сложные модели могут иметь следующий вид:

$$\begin{aligned} y_j &= \theta_j + w_j \cdot u, j = 1, \dots, q, \\ u &= f_0(x, w_0), \end{aligned}$$

где $f_0(x, w_0)$ – функция преобразования скрытых слоев нейросети (w_0 – их блок параметров) за исключением последнего, который содержит q линейных нейронов, $w_j, u \in R^m$, т.е. $f_j(x) = \theta_j + w_j \cdot f_0(x, w_0)$.

Для каждой пары (x_k, y_k) определяется минимальная величина потерь для моделей $f_1, \dots, f_q$:

$$\ell_k(w) = \min_{j=1, \dots, q} \ell_{kj}(w),$$

где $k = 1, \dots, N$,

$$\ell_{kj}(w) = \varrho(y_k - f_j(x_k; w))$$

– потери j -й для входа x_k со значением y_k на выходе, $\varrho(r)$ – дифференцируемая выпуклая функция потерь. Например,

$$1) \varrho(r) = \frac{1}{2}r^2;$$

$$2) \varrho(r) = \sqrt{\varepsilon^2 + r^2} - \varepsilon.$$

Точка x_k относится к компетенции моделей, для которых $\ell_{kj}(w) = \ell_k(w)$.

Отметим, что можно заменить $\min$ на дифференцируемую функцию мягкого минимума $SM_\lambda(u_1, \dots, u_N)$, где $\lambda > 0$, которая обладает следующим свойством:

$$\lim_{\lambda \rightarrow +\infty} SM_\lambda\{u_1, \dots, u_q\} = \min\{u_1, \dots, u_q\}.$$

Например, функция мягкого минимума:

$$SM_\lambda\{u_1, \dots, u_q\} = -\frac{1}{\lambda} \ln(e^{-\lambda u_1} + \dots + e^{-\lambda u_q}).$$

Минимальное значение потерь моделей $f_1, \dots, f_q$ для k -го входа тогда имеет вид

$$z_k = \ell_k(w) = SM_\lambda\{\ell_{k1}(w), \dots, \ell_{kq}(w)\}.$$

Обычно потери от ошибок оцениваются как среднее арифметическое:

$$Q(w) = \frac{1}{N} \sum_{k=1}^N \ell_k(w).$$

Оптимальный блок параметров w^* должен минимизировать целевую функцию $Q(w)$:

$$w^* = \arg \min_w Q(w)$$

Робастная постановка задачи

Существенная проблема может возникнуть, если исходные данные содержат выбросы. Под выбросами понимается часть данных, которая су-

существенно неадекватна ни одной из моделей регрессионных закономерностей между входами x и выходом y . Это может привести к тому, что в наборе значений потерь $\{z_1, \dots, z_N\}$ также будут содержаться выбросы. Как следствие, оценка эмпирического риска становится существенно искаженной. В результате решения задачи минимизации $Q(w)$ для таких данных, как правило, получаются также искаженные значения оптимальных параметров w^* .

С 80-х годов прошлого века применяется подход к преодолению влияния выбросов, основанный на применении функций $\varrho(r)$ в представлении функции потерь, которые растут асимптотически существенно медленнее, чем r^2 или даже ограничены. Во многих случаях это помогает преодолеть влияние выбросов. Однако остаются ситуации, когда такой подход все же не достигает цели.

В настоящей работе предлагается расширенный подход для преодоления этой проблемы, основанный на замене среднего арифметического в представлении целевой функции Q , на дифференцируемую оценку среднего значения, нечувствительную к выбросам [7–8]. Это позволяет избежать или существенно уменьшить искажения значений целевой функции Q из-за выбросов и, как следствие, уменьшить искажение w^* . Т.е., используя дифференцируемую оценку среднего значения M , нечувствительную к выбросам, ставится следующая задача поиска параметров моделей регрессии:

$$Q_M(w) = M\{\ell_1(w), \dots, \ell_N(w)\}.$$

В данной работе будем использовать функцию среднего арифметического с предварительным цензурированием аргументов:

$$WM_{\rho,\alpha}\{z_1, \dots, z_N\} = \frac{1}{N} \sum_{k=1}^N \min(z_k, \tilde{z}_{\rho,\alpha}),$$

где $\tilde{z}_{\rho,\alpha}$ – пороговое значение, которое находится как решение следующей задачи:

$$\tilde{z}_{\rho,\alpha} = \operatorname{argmin}_u \sum_{k=1}^N \rho(z_k - u),$$

где $\rho(r)$ – выпуклая функция. Приближенное значение $\tilde{z}_{\rho,\alpha}$ можно вычислить при помощи следующей итерационной процедуры:

$$u^{t+1} = \frac{\sum_{k=1}^N \varphi(z_k - u^t) z_k}{\sum_{k=1}^N \varphi(z_k - u^t)},$$

где $\varphi(r) = \rho'(r)/r$. Если ρ дважды дифференцируема, то $WM_{\rho,\alpha}\{z_1, \dots, z_N\}$ дифференцируема с частными производными:

$$\frac{\partial WM_{\rho,\alpha}\{z_1, \dots, z_N\}}{\partial z_k} = \frac{\rho''(z_k - \tilde{z}_{\rho,\alpha})}{\rho''(z_1 - \tilde{z}_{\rho,\alpha}) + \dots + \rho''(z_N - \tilde{z}_{\rho,\alpha})}.$$

Искомые параметры удовлетворяют системе нелинейных уравнений:

$$\sum_{k=1}^N \frac{\partial M\{z_1, \dots, z_N\}}{\partial z_k} \sum_{j=1}^q \frac{\partial SM_{\lambda}\{u_{k1}, \dots, u_{kq}\}}{\partial x_j} \nabla \ell_{kj}(w) = 0,$$

где $z_k = SM_{\lambda}\{u_{k1}, \dots, u_{kq}\}$, $x_j = \ell_{kj}(w)$.

Для ее решения можно воспользоваться схемой итеративного перевзвешивания:

$$w^{t+1} = \arg \min_w Q_M^t(w),$$

где

$$\begin{aligned} Q_M^t(w) &= \sum_{k=1}^N \sum_{j=1}^q v_{kj}^t \ell_{kj}(w_j), \\ v_k^t &= \frac{\partial M\{z_1^t, \dots, z_N^t\}}{\partial z_k} \frac{\partial SM_{\lambda}\{x_{k1}^t, \dots, x_{kq}^t\}}{\partial x_j}, \\ z_k^t &= SM_{\lambda}\{x_{k1}^t, \dots, x_{kq}^t\}, x_{kj}^t = \ell_{kj}(w^t). \end{aligned}$$

Критерий останова: если для заданного $\varepsilon > 0$

$$|Q_M\{w^{t+1}\} - Q_M\{w^t\}| < \varepsilon,$$

то процесс поиска завершается.

Процедура итеративного перевзвешивания

- 1) $t \leftarrow 0$
- 2) Выбираются начальные значения параметров $w_1^0, \dots, w_q^0$.
- 3) Рассчитываются веса v_{kj}^t и решаются задачи для поиска w^{t+1} .
- 4) Если критерий останова выполняется, то процедура завершается. Иначе $t \leftarrow t + 1$ и переходим к шагу 3.

Наглядные примеры

В данных двух примерах часть точек расположены вдоль заданных прямых, остальная часть – выбросы – сгенерированы так, чтобы классический подход приводил к смещению прямых. В обоих случаях выбрана функция $\varrho(r) = \sqrt{\varepsilon^2 + r^2} - \varepsilon$, которая является существенно более робастной, чем $\varrho(r) = \frac{1}{2}r^2$. Но даже с такой функцией классический подход терпит неудачу. Применение же робастной оценки среднего $WM_{\rho, \alpha}$ вместо среднего арифметического позволяет полностью преодолеть влияние выбросов. Выбор α соответствует отношению числа точек, не являющихся выбросами, к их общему количеству.

На рис. 2 представлены результаты с двумя прямыми.




Рис. 2. Пример с двумя прямыми

На рис. 3 представлены результаты с тремя прямыми.




Рис. 3. Пример с тремя прямыми

На левых рисунках – результаты классического подхода, на правом – результаты робастного подхода.

Заключение

В настоящей работе описано расширение классической постановки задачи поиска нескольких регрессионных зависимостей, присутствующих в данных, путем использования более общих оценок среднего значения вместо среднего арифметического для оценки средних потерь (применяется в классическом подходе). Это позволяет преодолеть влияние выбросов за счет особенности робастных оценок среднего значения, используемых в настоящей работе.

Эффект снижения влияния выбросов достигается за счет малости весов примеров, которые являются выбросами (как правило, с большими значениями ошибок). При новом подходе веса точек вычисляются по формуле вида

$$v_k = \psi(z_k - \tilde{z}_{\rho, \alpha}),$$

где $\psi(z)$ – неотрицательная убывающая функция от z , $\tilde{z}_{\rho, \alpha}$ – величина робастной оценки среднего значения $z_1, \dots, z_N$, которая нечувствительна или малочувствительна к выбросам. Существенной особенностью является тот факт, что величины весов в процедуре итеративного перевзвешивания являются функцией отклонения z_k от среднего значения. В классическом же подходе веса точек в процедуре итеративного перевзвешивания пересчитываются по формуле вида:

$$v_k = \psi(z_k).$$

В результате в рамках предложенного здесь метода точки, соответствующие выбросам, получают более малые значения весов, чем в рамках классического, которые достаточны для того, чтобы преодолеть их влияние.

Список литературы

1. Vainsencher D., Mannor S., Xu H. Learning multiple models via regularized weighting // NIPS'13: Proceedings of the 26th International Conference on Neural Information Processing Systems. 2013. V. 2. P. 1977–1985.
2. Cheng L., Kovachki N., Welborn M., Miller T. Regression-clustering for Improved Accuracy and Training Cost with Molecular-Orbital-Based Machine Learning. 2019. <https://arxiv.org/abs/1909.02041>

3. Gitman I., Chen J., Lei E., Dubrawski A. Novel prediction techniques based on clusterwise linear regression. 2018. <https://arxiv.org/abs/1804.10742>
4. Torti F., Perrotta D., Riani M., Cerioli A. Assessing trimming methodologies for clustering linear regression data // *Advances in Data Analysis and Classification*. 2019. V. 13, N 1. P. 227–257.
5. Cohen E. Some effects of inharmonic partials on interval perception // *Music Perception*. 1984. V. 1. P. 323–349.
6. Duncan O.D. A socioeconomic index for all occupations // *Occupations and Social Status* / ed. by Reiss A.J. New York : Free Press, 1961. P. 109–161/
7. Calvo T., Beliakov G. Aggregation functions based on penalties // *Fuzzy Sets and Systems*. 2010. V. 161, N 10. P. 1420–1436.
8. Shibzukhov Z.M. Minimizing robust machine learning based on the principle of mean estimates // *Advances in Intelligent Systems and Computing*. Springer International Publishing. 2020. V. 1310. P. 472–477.

E.A. ENGEL, N.E. ENGEL

Katanov State University of Khakassia, Abakan

ekaterina.en@gmail.com

THE INTELLIGENT TIMES SERIES FORECASTING FRAMEWORK*

Most successful applications of machine learning to real-world forecasting tasks have been achieved using deep networks of rather large size disregard to task's complexity and overfitting problems. This paper presents the effective intelligent times series forecasting framework that provides an automatic creation of an optimum architecture of the modified fuzzy neural net about a forecasting task's complexity. We verified the developed intelligent times series forecasting framework by solving the PV array power forecasting task. The validity and advantages of the developed intelligent two days ahead hourly PV array power forecasting system are demonstrated using numerical simulations. Based on the fuzzy hour's state of cloudiness, the created modified fuzzy neural net provides an effective two days ahead hourly PV array power forecasting under various uncertainties. The simulation results show that the proposed intelligent two days ahead hourly PV array power forecasting system based on a modified fuzzy neural net achieves competitive performance, as compared to a classical recurrent neural net trained by the Levenberg-Marquardt algorithm.

Keywords: *modified fuzzy neural net, random perturbations, photovoltaic array, PV array power forecasting.*

1. Introduction

Most successful applications of machine learning to real-world forecasting tasks have been achieved using deep networks of rather large size without regard to task's complexity [1]. More importantly, as the number of parameters in the neural network increases, overfitting problems may arise, with devastating effects on the generalization performance. Thus, design methods and tools for generating optimal architectures of an artificial neural network about a forecasting task's complexity will be needed. Therefore, combining the automatic intelligent methods such as modified fuzzy neuronet (MFNN) [2], modified multi-dimension quantum-behaved particle swarm optimization (MD QPSO) and the

* The reported study was funded by RFBR and Republic of Khakassia according to the research project № 19-48-190003.

Group Method of Data Handling (GMDH) algorithm [3] within an intelligent computation framework is a promising solution. This paper considers the development of an effective intelligent times series forecasting framework that remains easy to implement. The intelligent times series forecasting framework based on the authors software [4] provides an automatic creation of an optimum architecture of the MFFN concerning a forecasting task's complexity. In order to automatic, create of the optimal architecture of a MFFN, which requests a global multi-dimensional optimization, and definition of optimal MFFN architecture we modify MD QPSO and develop hierarchical encoder of the dimension component of particles. We further improved MFNN based on above-mentioned methods and developed the intelligent times series forecasting framework which verified by solving the PV array power forecasting task in a general manner.

Photovoltaic (PV) systems proved to be one of the most effective tools for producing clean energy. However, PV systems are not stable due to complex dynamics of the external factors such as insolation, temperature etc. Therefore, it is very important to provide accurate forecasting of PV array power in order to its effective integration into the power grid system of the region.

There are many machine learning methods for PV array power forecasting from advanced feed forward neural networks with residual connections [5] to convolutional neural networks [6], and Recurrent Neural Networks (RNN) [7], along with their many variants such as Echo-state Network [8], Long-Short Term Memory [9], and Gated Recurrent Unit [10]. However, in all above-mentioned researches the PV array power is forecast based on networks of large size without regard to task's complexity.

We generated the intelligent two days ahead hourly PV array power forecasting system based on the developed intelligent times series forecasting framework. We fulfilled the intelligent two days ahead hourly PV array power forecasting system based on the MFNN, which includes an RNN, fuzzy rules and RNNs. We fulfilled a comparison simulations study of the intelligent two days ahead hourly PV array power forecasting system based on the tuned MFNN, which compared against a classical RNN trained by the Levenberg-Marquardt algorithm. The validity and advantages of the developed intelligent two days ahead hourly PV array power forecasting system are demonstrated using numerical simulations. Based on the fuzzy hour's state of cloudiness, the created modified fuzzy neural net provides an effective two days ahead hourly PV array power forecasting under various uncertainties. The simulation results show that the proposed intelligent two days ahead hourly PV array power fore-

casting system based on MFNN achieves competitive performance, as compared to a classical RNN trained by the Levenberg-Marquardt algorithm.

2. The intelligent times series forecasting framework

Given a set of r -dimensional inputs I and desired outputs T , (we assume that the T is one-dimension vector), we split the data $s=(I,T)$ into two equal size sets, by computing the mean over s and sorting the data based on the distance from this mean. Every other data point belonged to a training set $\tilde{s}$, the rest for a test set $\check{s}$. This splitting procedure is the same one from GMDH algorithm [2].

We calculated the estimate of Lipschitz constant of the data set s as follows:

$$\Lambda_D = \max_{i \neq j} \frac{\|T^i - T^j\|}{\|I^i - I^j\|}. \quad (1)$$

The MFNN includes a two-layer RNN, fuzzy rules and two two-layered RNNs. The MFNN architecture's parameters (a hidden neurons' number— $d_{h_j} \in \overline{1..H}$, corresponded biases and weights, a number of RNN's delays — $d_{q_j} \in \overline{1..L}$, $j \in \overline{1..L}$) were encoded into particles X .

We calculated the dimension of particle X as follows:

$$D(d_{h,q}) = \sum_{j=1}^3 d_{h_j} \cdot (r + 3 * d_{q_j}). \quad (2)$$

We encoded the dimension component of particle X as

$$d = (d_{h_1}, d_{h_2}, d_{h_3}, d_{q_1}, d_{q_2}, d_{q_3}) \\ \in \{d_{\min} = (1,1,1,1,1,1), d_{\max} = (H, H, H, L, L, L)\}. \quad (3)$$

We calculated the estimate of Lipschitz constant of an RNN as follows:

$$\Lambda_h \leq H\sqrt{r + 2 * L}. \quad (4)$$

Then we evaluated the maximum number of hidden units H as follows:

$$H \geq \Lambda_D / \sqrt{r + 2 * L}. \quad (5)$$

We defined a fitness function based on the Chebyshev criterion as follows:

$$f(X) = \max_{\check{s}} (T^t - P^{X,t}) / T^t, \quad (6)$$

where $P^{X,t}$ is the value which generated based on MFNN with architecture X .

We develop the intelligent times series forecasting framework based on the authors software [4]. The intelligent times series forecasting framework includes a splitting procedure from GMDH algorithm, evaluation of the maximum number of hidden units H by eq. (5) and the modified MD QPSO.

2.1 The modified MD QPSO

We elaborate the modified MD QPSO (the termination criteria are $\{T, \varepsilon_c, \dots\}$; S is the number of particles) as follows:

Step 1. For $\forall X \in \{1, S\}$ do:

Generate $d_{x,q}(1) = \text{abs}(N(0,1))$, $d_{x,q}(t) = \text{abs}(N(0,1))$ – current encoded dimension of X position, $q = \overline{1..3}$.

Initialize $\tilde{d}_x(0) = d_x(1)$, $\tilde{d}_x(t)$ – personal best encoded dimension of position X.

For $\forall d \in \{d_{\min}, d_{\max}\}$ do:

Generate $x_X^d(1)$ based on Nguen-Widrow method the

$x_{X,j}^{d_X(t)}(t) \in (X_{\min}, X_{\max})$ is jth component of the particle X position;

Initialize $y^d(t) = x_X^d(1)$, $gbest^d(t) = x_X^d(1)$, $gbest_j^d(t)$ is jth component of a global best swarm' position in encoded dimension d. End For. End For.

Step 2. For $\forall t \in \{1, T\}$ do: For $\forall X \in \{1, S\}$ do:

If $f(x_X^{d_X(t)}(t)) < f(y_X^{d_X(t-1)}(t-1))$ then Do: $y_X^{d_X(t)}(t) = x_X^{d_X(t)}(t)$

If $f(x_X^{d_X(t)}(t)) > f(y_X^{\tilde{d}_x(t-1)}(t-1))$ then $d_x(t) = d_x(t-1)$ else

$d_x(t) = d_x(t)$ End If. else $y_X^{d_X(t)}(t) = y_X^{d_X(t)}(t-1)$ End If.

If $f(x_X^{d_X(t)}(t)) < \min(f(y_X^{d_X(t)}(t-1)), \min_{1 \leq p < X}(f(x_p^{d_X(t)}(t))))$ then Do:

$g(d_X(t)) = X$, $g(d)$ is an index of the global best swarm' particle.

If $f(x_X^{d_X(t)}(t)) < f(gbest^{dbest}(t-1))$ then $dbest = d_X(t)$, $dbest$ is a global best swarm' encoded dimension End If. End If.

In other encoded dimensions $\forall d \in \{d_{\min}, d_{\max}\} - d_X(t)$ do updates $y_{X,j}^d(t) = y_{X,j}^d(t-1)$, $gbest_j^d(t) = gbest_j^d(t-1)$. End For.

If $(I > IterNo \text{ OR } f(x_{g(d_X(t))}^{dbest}) < \varepsilon_c)$ then Stop. End If.

Step 3. $E = f(x_{g(d_X(t))}^{d_X(t)})$. While $(I < IterNo \text{ OR } E > \varepsilon_c \text{ OR } \max_{\bar{s}}(T^t - P^{X,t}) / \max_{\bar{s}}(T^t - P^{X,t}) \approx 1)$ $\Delta W_l = [J_l^T J_l + \mu * X]^{-1} J_l^T E$, J_l is the Jacobian matrix, μ is the learning rate.

Step 4. Calculate $W_l = W_l + \Delta W_l$, $x'_{g(d_X(t))}^{d_X(t)}$, $E' = f(x'_{g(d_X(t))}^{d_X(t)})$

If $E' < E$ then $W_l = W_l + \Delta W_l$; $\mu = \mu\beta$; $E' = E$; Go to step 3 else $\mu = \mu/\beta$; go to step 4.

Step 5. For $\forall X \in \{1, S\}$ do: For $\forall j \in \{1, d_X(t)\}$ do: Generate u and k as $U(0,1)$; γ and G has Laplace distribution; if $k \geq 0.5$ then $\alpha = 2$ else $\alpha = 1$; β is contraction–expansion coefficient;

$$x_{X,j}^{d_X(t)}(t+1) = \frac{G \cdot y_{X,i}^{d_X(t)}(t) + \gamma \cdot gbest_j^{dbest}(t)}{G + \gamma} + (-1)^\alpha \beta \cdot \ln \ln \left(\frac{1}{u} \right) \cdot$$

$$\left| \frac{\sum_{i=1}^S y_{g(d),i}^{d_X(t)}(t)}{S} - x_{X,j}^{d_X(t)}(t) \right|,$$

$$x_{X,j}^{d_X(t)}(t+1) \leftarrow \begin{cases} x_{X,j}^{d_X(t)}(t+1) & \text{if } X_{\min} \leq x_{X,j}^{d_X(t)}(t+1) \leq X_{\max} \\ U(X_{\min}, X_{\max}) & \text{else} \end{cases}$$

In other encoded dimensions $\forall d \in \{d_{\min}, d_{\max}\} - d_X(t)$ do updates
 $x_{X,j}^d(t+1) = x_{X,j}^d(t)$. End For.

$$\text{Computed}_{X,q}(t+1) = \frac{G \cdot d_{X,q}(t) + \gamma \cdot dbest}{G + \gamma} + (-1)^\alpha \beta \cdot \left| \frac{\sum_{i=1}^S d_{g(d),i}(t)}{S} - \right.$$

$$d_{X,q}(t) \left. \right| \cdot \ln \ln \left(\frac{1}{u} \right),$$

$$d_{X,q}(t+1) = \begin{cases} d_{X,q}(t+1) & \text{if } D_{\min,q} \leq d_{X,q}(t+1) \leq D_{\max,q} \\ d_{X,q}(t) & \text{else} \end{cases}, \text{ End For.}$$

End For.

The modified MD QPSO elaborates an inter-dimensional quantum-behaved swarm's search for both positional and dimensional optimum and creates a global best swarm' encoded dimension $dbest$. The modified MD QPSO automatically generates an optimum architecture of the MFFN – $gbest$.

2.2. The intelligent two days ahead hourly PV array power forecasting System

We calculate the total rate of insolation G_C striking a PV array on a clear day as follows:

$$G_C = A e^{-km} (\cos \beta \cos(\phi_s - \phi_C) \sin \Sigma + \sin \beta \cos \Sigma + (C + \cos \Sigma)/2 + p(\sin \beta + C)(1 - \cos \Sigma)/2)$$

where m – the air mass, β – the altitude angle, ϕ_s – the solar azimuth angle, ϕ_C – the PV module azimuth angle, p – the reflection factor, Σ – the PV module tilt angle, C – the sky diffuse factor, A and k – parameters related to the Julian day number.

The surface insolation fluctuates accordingly with the cloudiness' dynamic (Figure 1).

We define a clear-sky index as follows: $C = G_s/G_C$, where G_s is the surface insolation, G_C is the clear-sky model's insolation.

Fig. 2 shows that the clear-sky index C is big and has similar shape on sunny days (05/18/16, 05/19/16) at the site of Abakan. In contrast, C is smaller and has more fluctuations on cloudy days (05/16/16, 05/17/16).




Fig. 1. The extraterrestrial insolation and the surface insolation at the site of Abakan




Fig. 2. The clear-sky index at the site of Abakan

We fulfilled the intelligent two days ahead hourly PV array power forecasting system based on the data

$$s_h^t = (I_h^t = (G0_h^t, C_h^{t-2}, P_h^{t-2}, l_h^t, a_h^t, R_h^t, W_h^t, d_h^t), T_h^t = P_h^t), \quad (7)$$

where $G0_h^t$ is the extraterrestrial insolation, P_h^t is the power from a PV array, P_h^{t-2} is the historical data of the power from a PV array, C_h^{t-2} is the historical data of clear-sky index, l_h^t is the cloudiness (%), R_h^t is the pressure, W_h^t and d_h^t are the wind speed and the wind direction, respectively, a_h^t is the ambient temperature, $h=10..18$, $t=1..1309$. It is to emphasize that l_h^t , R_h^t , W_h^t , d_h^t , a_h^t are daily average parameters of the weather forecast. The data (7) was collected at the Abakan solar plant from 03/16 through 09/19.

We generated the intelligent two days ahead hourly PV array power forecasting system based on the developed intelligent times series forecasting framework.

We described the fulfillment of the intelligent two days ahead hourly PV array power forecasting system briefly as follows.

Step 1. All samples of the data (7) s^i were classified into two groups according to hour's state of cloudiness: A_1 is sunny hour ($C^{i1} = 1$), A_2 is cloudy hour ($C^{i2} = -1$). This classification generates vector with elements C^i .

Step 2. We created the two-layer network: $Y(s^i)$. The vector s^i was the network's input. The vector C^i was the network's target. We formed membership function $\mu_j(s)$ based on the two-layer network $Y(s^i)$ as follows

$$\mu_1(s^i) = \begin{cases} Y(s^i), & \text{if } Y(s^i) \geq 0 \\ 0, & \text{if } Y(s^i) < 0 \end{cases}, \quad \mu_2(s^i) = \begin{cases} |Y(s^i)|, & \text{if } Y(s^i) < 0, \\ 0, & \text{if } Y(s^i) \geq 0, \end{cases} \quad (8)$$

This step provides the fuzzy sets A_j , (A_1 is sunny hour, A_2 is cloudy hour) with membership function $\mu_j(s)$, $j = \overline{1..2}$.

Step 3. We created the MFNN based on the data (7). The MFNN includes $Y(s^i)$ and two RNNs F_j . The MFNN architecture's parameters (number of nodes in hidden layer, corresponded weights and biases) have been encoded into particles X . We calculate the maximum number of hidden units H by eq. (5). We calculate the dimension component of particle X by eq. (2), $r=8$. To make the intelligent two days ahead hourly power forecasting from the PV array system become adaptive, it needs to have some idea of how the actual hourly power differs from it expected the two days ahead hourly power, so that the RNN F_j can recalibrate its value intelligently during run time, and try to eliminate the constant tracking error. We give the RNN $F_j(\mu_j(s), s)$ an extra input $\mu_j(s)$ which corresponds to the value of membership function $\mu_j(s)$. This input signal of the RNNs $F_j(\mu_j(s), s)$ will give useful feedback for providing the two days ahead hourly power forecasting value during the dynamically changing times series (4). This forecasting approach does provide a more intelligent algorithm of generating the two days ahead hourly power forecasting value u on the basis of a MFNN.

We used modified MD QPSO as an optimization algorithm which we described in subsection 2.1. We used function (6) as a fitness function for the modified MD QPSO. This step provides trained MFNN $best(d_h)$ which create the forecasted power of the PV array $u(best(d_h))$ – best solution X generated by the modified MD QPSO).

If-then rules are defined as:

$$\Pi_j: \text{IF } s \text{ is } A_j \text{ THEN } u = F_j(\mu_j(s), s), \quad j = \overline{1..2}. \quad (9)$$

Simulation of the trained MFNN briefly can be described as follows.

Step 1. Aggregation antecedents of the rules (9) maps input data s into their membership functions and matches data with conditions of rules. These mappings are then activating the k rule, which indicates the k hour's state of cloudiness and correspondent k RNN $F_k(\mu_j(s^t), s^t)$, $k \in \overline{1..2}$.

Step 2. According the k mode the correspondent k RNN $F_k(\mu_j(s^t), s^t)$ (trained based on the data s^{t-2} (7)) generates the two days ahead hourly power forecasting value $u = F_j(\mu_j(s^t), s^t)$.

3. Simulation and Results

To illustrate the benefits of the MFNN in the two days ahead forecasting hourly power from the PV array, we revisited the numerical examples from the previous sections 2.

We created the intelligent two days ahead hourly PV array power forecasting system within the developed intelligent times series forecasting framework based on the training set of the data (7) from 03/16 through 04/19. We trained the MFNN using modified MD QPSO with Laplace distribution (MD QPSO-LD). We calculate the maximum number of hidden units H by eq. (2), $H = 14$. Due to obtain statistical results, we perform 120 modified MD QPSO and PSO runs with following parameters: $n = 250$ (we use 250 particles), $T = 450$ (the maximum number of iterations is 450). Figure 3 represents that the modified MD QPSO has confidently more the convergence speed than the modified PSO over training set of the data (7).

The modified MD QPSO created the optimum architecture of the MFNN *gbest* with $D(dbest = d_{h=(5,7,10),q=(2,2,2)}) = 336$. This MFNN includes the two-layered RNN $Y(s^i)$ with five hidden neurons (number of delays is two) and then the two two-layered RNNs $F_k(\mu_k(s), s)$ with seven and ten hidden neurons, correspondently (number of delays is two), $k = \overline{1..2}$.

Fig. 4 represents the plot of the measured power from the Abakan solar plant on the test set of the data (7) from 05/19 through 09/19 in comparison to forecasted power of the MFNN and the RNN (two-layered with ten hidden neurons, the number of delays is two), which we generated by the Levenberg-Marquardt algorithm based on training set of the data (7).




Fig. 3. The mean convergence curves




Fig. 4. The forecasted power curves

Table 1 demonstrates that fitness function (6) of the MFNN in sunny hours is quite small as compared with the RNN, which we generated as two-layered based on data (7) with ten hidden neurons, the number of delays is two. The performance of the MFNN is changing in sunny and cloudy hours (Table 1).

Table 1

A two days ahead forecasting of the hourly power from the PV array:
comparison of results

	MFNN <i>gbest</i> solution		RNN solution	
	Sunny	Cloudy	Sunny	Cloudy
The fitness function (6) (%)	3,74	4,67	9,82	18,73

Nevertheless, the MFNN effectively tracks the complex dynamics of real measured data in cloudy hours. Table 1 indicates that the MFNN outperforms the RNN, especially in the cloudy hours. The performance of the MFNN trained by the proposed algorithm is superior to the RNN trained by the Levenberg-Marquardt algorithm, especially on cloudiness condition.

4. Conclusions

We developed an effective intelligent times series forecasting framework on the basis of combining the MFNN, MD QPSO and the GMDH algorithm. The intelligent times series forecasting framework based on the authors software provides an automatic creation of an optimum architecture of the MFFN concerning a forecasting task's complexity. In order to automatic, create of the optimal architecture of a MFFN, which demands a global multi-dimensional optimization, and definition of optimal MFFN architecture we modified MD QPSO and developed hierarchical encoder of the dimension component of particles. We further improved MFNN based on above-mentioned methods and developed an intelligent times series forecasting framework which verified by solving the PV array power forecasting task. It is shown that the intelligent two days ahead hourly PV array power forecasting system based on a MFNN is robust to various uncertainties. Unlike popular approaches to nonlinear approximation, a MFNN is used to approximate the times series' law and not its nonlinearities, which makes it suitable over a wide range of nonlinearities. Compared to standard neural networks, including RNN, the intelligent two days ahead hourly PV array power forecasting system based on a MFNN produces good performance. Based on the fuzzy hour's state of cloudiness, the created MFNN provides an effective two days ahead hourly PV array power forecasting under various uncertainties. Simulation comparison results for two days ahead forecasting of PV array power demonstrates the effectiveness of the MFNN generated by modified MD QPSO as compared with the RNN trained by the Levenberg-Marquardt algorithm. It is our contention that the proposed intelligent times series forecasting framework can have generic applications to

other kinds of forecasting tasks, and produce a competitive alternative algorithm to standard neural networks.

References

1. Ying X. An Overview of Overfitting and its Solution // Journal of Physics: Conference Series. 2019. V. 1168.
2. Ivakhnenko A.G. Continuity and Discreteness. Kiev: Naukova Dumka. 1990.
3. Engel E., Kovalev I., Testoyedov N., Engel N.E. Intelligent Reconfigurable Photovoltaic System // Energies. 2021. V/ 14. P. 7969.
4. The module of the modified fuzzy neural net. M.: Federal Service for Intellectual Property (Rospatent), Certificate about State registration of software № 2021681065, 2021.
5. Chen K., Chen K., Wang Q., He Z., Hu J., and He J. Short-term load forecasting with deep residual networks // IEEE Transactions on Smart Grid. 2018. P. 1–1.
6. Kuo P.-H., Huang C.-J. A high precision artificial neural networks model for short-term energy load forecasting // Energies. 2018. V. 11, N 1.
7. Bianchi F.M., Maiorino E., Kampffmeyer M.C., Rizzi A., Jenssen R. An overview and comparative analysis of recurrent neural networks for short term load forecasting // <http://arxiv.org/abs/1705.04378>. 2017.
8. Bianchi F.M., Santis E.D., Rizzi A., Sadeghian A. Short-term electric load forecasting using echo state networks and pca decomposition // IEEE Access. 2015. V. 3. P. 1931–1943.
9. Bouktif S., Fiaz A., Ouni A., Serhani M. Optimal deep learning lstm model for electric load forecasting using feature selection and genetic algorithm: Comparison with machine learning approaches // Energies. 2018. V. 11, N 7. P. 1636.
10. Wang Y., Liu M., Bao Z., Zhang S. Short-term load forecasting with multi-source data using gated recurrent unit neural networks // Energies. 2018. V. 11. P. 1138.
11. Tavares C.A.P., Leite K.T.F., Suemitsu W.I., Bellar M.D. Performance evaluation of PV solar system with different MPPT methods // IECON '09, 35th Annual Conference of IEEE. Industrial Electronics. 2009. P. 719-724.
12. Kumar A., Chaudhary P., Rizwan M. Development of fuzzy logic based MPPT controller for PV system at varying meteorological parameters // 2015 Annual IEEE India Conference (INDICON). New Delhi. 2015. P. 1–6.

НЕЙРОИНФОРМАТИКА И ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ

E.I. ZAYTSEV, E.V. NURMATOVA

MIREA - Russian Technological University, Moscow, Russia
zajcev@mirea.ru

ON THE ORGANIZATION OF THE MULTI-AGENT KNOWLEDGE REPRESENTATION AND PROCESSING SYSTEM

This paper discusses the structure and functional organization of the Multi-Agent Knowledge Representation and Processing System (MAKRPS). An agent-based approach to the development of distributed intelligent systems, which allows integrating knowledge-based reasoning mechanisms with neural network models, is proposed. The structure of multi-agent solver, methods that implement different types of queries to the Knowledge Base, and methods for reinforcement learning virtual agents are described. The problem of optimizing the logic of data structure distribution among the nodes of the system in order to increase the speed of processing requests to the knowledge base is considered. Data collection from remote nodes of the Multi-Agent Knowledge Representation and Processing System is carried out in the operational databases of large volumes, which are synchronized to solve various kinds of analytical problems. The optimal structure ensures the efficiency of the MAKRPS on multi-computers. As a result of solving the optimization problem, the system is divided into a number of clusters that have minimal information connectivity with each other. Solving the problem of synthesizing the optimal data structure is of great practical value for designing the logical structures of knowledge bases, for forming the specifications of the queries and customizing the knowledge base.

Keywords: *Distributed System, Multi-Agent System, Reinforcement Learning, Data Localization Optimization, Time Series, Forecasting.*

Introduction

Multi-Agent Knowledge Representation and Processing System consists of a set of interacting rational software objects (agents), which are capable of controlling their behavior, perceiving the environment, learning in this environment, timely responding to events occurring in this environment [1-5]. In a

broad sense, rationality means the ability of an agent to act correctly in a given situation. An agent who is able to choose an optimal action in a given situation demonstrates perfect rationality. The concept of rationality can be applied to wide variety of agents acting in any environment. One formal approach to rational behavior is based on logical calculus. In logical systems of knowledge representation and processing, the emphasis is on the realization of correct logical inference.

In traditional systems based on a logic model, the solution of a complex problem is treated as a search on a reduction graph (AND/OR connection graph). Efficient parallel algorithms for AND/OR graph processing have been developed for multiprocessors (Shared Memory Processors systems, SMP). However, these algorithms are not suitable for multicomputer (No Remote Memory Accesses systems, NORMA). Multicomputer use distributed computation model with message passing instead of parallel computation methods using shared variables.

To use parallel search algorithms on the reduction graph in NORMA systems (in particular, in cluster systems) it is necessary to organize a single virtual address space (Distributed Shared Memory, DSM). A DSM mechanism can be used for workstation clusters. However, the performance of clusters using the DSM is not high. To implement a Distributed System, programmers usually prefer to use more complex but predictable models with message passing.

In parallel intelligent systems software modules are highly coupling, they use a single address space and shared variables. Classical intellectual solver of single-processor or multiprocessor computing system (SMP) is a monolithic application. Such an intelligent solver has a global view of the problem and uses a complete and consistent knowledge base. In turn, the Multi-Agent Knowledge Representation and Processing System use microservice architecture. A feature of the microservice architecture is that microservices are loosely coupled. The MAKRPS software agent has only partial knowledge of the problem and solves only some subtask.

Intelligent Agent Knowledge allows it to formulate appropriate judgments only with a certain degree of certainty. Probability theory can be used to deal with degrees of certainty and to develop models that take into account this or that type of uncertainty. Another type of uncertainty, which is substantively different from stochastic uncertainty, is linguistic uncertainty, that is, a linguistic description (qualitative assessment) of a situation or event, rather than a quantitative assessment of whether the event will or will not happen in the future.

The MAKRPS uses fuzzy logic to deal with uncertainty, which allows ex-

perts to use qualitative estimates [5-8]. Software agents of the MAKRPS are capable of deriving fuzzy conclusions based on fuzzy conditions or assumptions and making fuzzy queries to the knowledge base [5].

The behavior of software agents improves (becomes more rational) by repeatedly solving the same problem. The environment provides information describing the state of the system. The agent interacts with the environment, observing the state and using this information to choose an action.

The MAKRPS uses reinforcement learning, in which the software agent learns from a series of reinforcements: rewards and punishments. The agent's actions change the environment, which goes to a new state. The environment returns the next state and reward to the agent. The cycle "state $\rightarrow$ action $\rightarrow$ reward" repeats until the problem is solved (Fig. 1).




Fig. 1. The reinforcement learning control loop

Signals s_t correspond to a state, a_t to an action, r_t to a reward at time t . The strategy according to which the agent chooses actions is a function that maps a set of states into a set of actions. The agent's task is to choose (by trial and error) the best action that maximizes the target function, which is the sum of the rewards received by the agent. There are various reinforcement learning algorithms. MAKRPS uses the Actor-Critic algorithm [9, 10] in which the strategy generates action and the value function critiques the actions. At the core of reinforcement learning is function approximation. The function approximation method use multilayer neural networks [10, 11].

Structure of the MAKRPS

MAKRPS uses a distributed computing model, in which a complex task is divided into separate subtasks that are solved by software agents interacting with each other through messaging. The ability to isolate individual, loosely coupled components in a system is the main method of successful scaling. Ob-

ject-oriented analysis and design methodology provides this capability. The idea of decoupling is the basis of most of the patterns of object-oriented programming, which can be successfully used to create a Multi-Agent Knowledge Representation and Processing System. Software agents of the same node communicate with each other using a local InterProcess Communication (IPC). Computing nodes of the MAKRPS are multiprocessors with shared memory. Agents of different nodes communicate through message exchange, the mechanism of which depends on the middleware used in the system. To improve the performance of the MAKRPS inter-node IPC is implemented using special system libraries (LibOS). The structure of the multi-agent solver is shown in Figure 2.




Fig. 2. Structure of the problem-oriented Multi-Agent Solver

Two types of software agents are used in the structure of a multi-agent solver: cognitive and reactive. Cognitive software agent for processing the knowledge of the problem components uses special Cognitive Data Structures (CDS) that describe the plan for solving the target problem and establish links between the reactive software agents.

Four types of methods are implemented for working with the knowledge base: comparison (CMP), association (ASS), analysis (ANS) and specification (VAL). CMP-method is called when comparing events or objects; ASS-method is used to receive responses to requests for relationships between objects and events; ANS-method realizes the logical analysis of events. Fuzzy queries can be used to specify objects in the MASKRP (VAL-method). Fuzzy queries allow to find records in the knowledge base that satisfy the query to a certain extent. Different types of membership functions can be used to implement fuzzy queries in the MAKRPS. In order to choose an accessory function best suited for a particular task, a knowledge expert needs to conduct a series of computational experiments.

The functional and structural organization of the multi-agent solver is described in more detail in [5].

By setting up protocols and making connections, the cognitive agent chooses different decision strategies. For example, the cognitive agent can set that the knowledge source, which is the first reactive agent, has the highest priority. Priorities of other knowledge sources are set, for example, according to the principle of decreasing priorities with increasing order numbers of reactive agents. This approach is used in the problem-oriented multi-agent solver, the structure of which is shown in Figure 2, where the first software agent of node 1 is associated with the highest-priority tables of the knowledge base: Table_1 and TableSov_1.

The agent-based model allows integrating knowledge-based reasoning mechanisms with neural network models. A software agent can act rationally without using logical inference. In some situations, a reflex action may be more successful than a slower action taken after logical inference. An artificial neural network is used to adequately respond to the reactive software agent to the events occurring in the environment. When an input vector characterizing the current situation is received, the neural network initiates the agent's action that most closely corresponds to the situation, and the agent transitions to a new state. Together with the actions network (Actor), the agent includes a module that implements the functions of a Critic.

Synthesis of distributed Cognitive Data Structure

Created Cognitive Data Structures may have a large dimensionality and, therefore, their loading and implementation is carried out in parts. For this purpose, the logical structure should be divided into a number of clusters that have the smallest interconnection under constraints on the dimensionality of clusters, as well as the degree of semantic proximity of logical records included in the

clusters. Equally important is the question of choosing the type of storage systems used.

Let us introduce a variable Z_{kj}^i that characterizes the use by the k -th query of the i -th information item allocated to the j -th logical record. Variable $X_{ij} = 1$ if the i -th data group is included in the j -th logical record; $X_{ij} = 0$ otherwise. Variable $a_{ik} = 1$ if the i -th data group is included in the k -th query; $a_{ik} = 0$ otherwise.

The variable Z_{kj}^i characterizes the use of the j -th logical record by the k -th query:

$$Z_{kj} = \begin{cases} 1, & \text{if } \sum_{i=1}^I a_{ik} x_{ij} \geq 1; \\ 0, & \text{if } \sum_{i=1}^I a_{ik} x_{ij} = 0. \end{cases} \quad (1)$$

The problem of distributed data structure synthesis according to the criterion of minimum total query execution time is formulated under the constraints on uniqueness of data sets inclusion in a record, on record length, on total number of logical record types in a structure, on time of data search by queries, on uniqueness of input nodes in a structure, and on their total number.

The results of such a distributed data structure synthesis problem are of important practical importance for designing an optimal structure and the possibility to form specifications for queries and adjustments of distributed data.

Let us consider an approximate algorithm for solving the problem of synthesizing an optimal distributed data structure by the criterion of minimum total query execution time, which consists of a sequence of steps.

Stage 1. Here the placement of data groups is determined by the criterion of minimum total traffic. To solve this problem, an approximate algorithm for the distribution of data clusters between the server and clients of the local network is used. At the first stage, the canonical data structure graph is reduced to an unlinked graph with the calculation of the "weight" of each data group. The weight of each group consists of the weight of the data group itself and the weight of the arcs, taking into account user requirements:

$$V_i = V_i^{\text{rp}} + V_{ii'}^{\text{cb}}, \quad (2)$$

where V_i^{rp} is the total weight of the data group; $V_{ii'}^{\text{cb}}$ is the weight of the arcs of the graph of the canonical data structure.

$$V_i^{\text{rp}} = \sum_{k=1}^{k_0} \sum_{p=1}^{p_0} \gamma_{kp}^3 \delta_{kp}^3 \vartheta_{pi}, \quad (3)$$

$$V_{ii'}^{\text{cb}} = \sum_{k=1}^{k_0} \sum_{p=1}^{p_0} \gamma_{kp}^3 \delta_{kp}^3 \vartheta_{pi} \sum_{i' \neq i}^I \vartheta_{pi'} a_{ii'}^\Gamma. \quad (4)$$

Then the weight of the i -th group is:

$$V_i = \sum_{k=1}^{k_0} \sum_{p=1}^{p_0} \gamma_{kp}^3 \delta_{kp}^3 \vartheta_{pi} (1 + \sum_{i' \neq i}^I \vartheta_{pi'} a_{ii'}^\Gamma), \quad (5)$$

where γ_{kp}^3 is the frequency of usage of queries by users; δ_{kp}^3 is the elements of the matrix for using queries users; ϑ_{pi} is the matrix for using data groups when executing queries; $a_{ii'}^\Gamma$ is the semantic contiguity matrix of data groups.

At the *second* step of the stage, the computer network graph is transformed to a disconnected graph with the calculation of the "weight" of each node:

$$V_r = t_r + \sum_{r' \neq r}^{R_0} t_{rr'}, \quad (6)$$

where t_r is the total average duration of data processing in the r -th node, consisting of the time of decomposition of the query into subqueries, route selection and connection establishment, etc.;

$t_{rr'}$ is the average duration of data transmission between nodes, determined based on the matrix of logical distances between the servers of the nodes of the computer network.

At the *third* step of the first stage, the matrix $V = \|v_{ir}\|$ is formed, the elements of which are the Cartesian product of the "weights" of each node by the "weights" of each data group:

$$v_{ir} = V_i \times V_r \text{ for } i = \overline{1, I}; r = \overline{1, R_0}.$$

At the *fourth* step of the first stage, the problem

$$\min_{\{x_{ir}\}} \sum_{i=1}^I \sum_{r=1}^{R_0} v_{ir} x_{ir} \quad (7)$$

is solved under the constraints:

– by the number of data groups, the localization of which is possible on one node

$$\sum_{i=1}^I x_{ir} \leq N_r, r = \overline{1, R_0} \quad (8)$$

– on the permissible redundancy of groups by network nodes

$$\sum_{r=1}^{r_0} x_{ir} \leq M_i, \quad (9)$$

$$\sum_{r=1}^{r_0} x_{ir} \leq M_i, i = \overline{1, I} \quad (10)$$

– on the amount of available external memory of the data storage system

$$\sum_{i=1}^I x_{ir} \rho_i \pi_i \leq \eta_r^{\text{B3y}}, \quad (11)$$

where ρ_i is the vector of group lengths in bytes; π_i is the vector of number of instances in groups; η_r^{B3y} is the amount of available memory on the server of the r -th host; $x_{ir} = 1$, if the i -th data group is included in the r -th network node; $x_{ir} = 0$ – otherwise.

This is a linear integer programming problem. Its solution makes it possible to determine the optimal localization of data groups by network nodes.

The solution of the linear integer programming problem allows you to determine the optimal structure of data groups placed on the nodes of the network.

Stage 2. At this stage the problems of optimal distribution of data groups of each node on the types of logical records by the criterion of the minimum total time of local data processing in each node of the network are solved. The number of synthesis tasks for this stage is determined by the number of network nodes.

The initial data are the subgraphs of the canonical data structure graph, as well as the time and volume characteristics of the subgraphs of their canonical structure, the set of user requests and network nodes [13, 14].

The synthesis problem for this stage is solved using approximate algorithms [2], with the following constraints: restrictions on the number of groups in a record, on the unique inclusion of groups in a record, on the cost of information storage, on the total query service time. As a result, the logical database structures for each node of the network are defined.

Stage 3: Localization of data by network nodes. Input data of the stage: the results of the previous stages and the characteristics of the database.

As a result of the proposed algorithm, the localization matrices of the set of data groups by types of logical records (the result of stage 1), and then the groups of records by network nodes are formed. The running time of the algorithms is also evaluated.

Conclusion

The article discusses the structure of the Multi-Agent Knowledge Representation and Processing System. An approach to improving the performance of the MAKRPS is proposed, which includes construction of optimal logical structures of distributed cognitive data. As a result of the implementation of the considered algorithm for the synthesis of optimal placement of data structures on remote nodes, the criteria and constraints for the optimality of such a structure have been selected. To prove the effectiveness of the proposed methodology, the simulation of sequential processing of queries to a distributed knowledge base of the MAKRPS using the existing and reference (typical) solutions was conducted. The overall data processing speed for the existing and reference solutions increased on average by 18%. Further work in the framework of this topic is to develop software that implements algorithms for searching for variants of the logical structure of the distributed knowledge base, which provides

the optimal value of a given criterion for the effectiveness of functioning and satisfies the main system, network and structural constraints.

References

1. Tarassov V.B. Ot mnogoagentnykh sistem k intellektual'nym organizatsiyam. Mjsscow : Editorial URSS. 2002. 352 p. (in Russian).
2. Wooldridge M. An Introduction to Multi-Agent Systems. John Willey & Sons, Ltd. 2009. 488 p.
3. Baranauskas R., Janaviciute A., Jasinevicius R., Jukavicius V. On Multi-Agent Systems Intellectics // Information technology and control. 2015. V. 44, N 1. P. 112–124.
4. Houhamdi Z., Athamena B., Abuzaineddin R., Muhairat M. A Multi-Agent System for Course Timetable Generation // TEM Journal. 2019. V. 8. P. 211–221.
5. Zaytsev E.I., Khalabiya R.F., Stepanova I.V., Bunina L.V. Multi-Agent System of Knowledge Representation and Processing // Proceedings of the Fourth International Scientific Conference «Intelligent Information Technologies for Industry» (IITI'19), Springer. 2020. P.131–141.
6. Darweesh S., Shehata H. Performance Evaluation of a Multi-Agent System using Fuzzy Model // 1st International Workshop on Deep and Representation Learning (IWDRL). 2018. P. 7–12.
7. Aly S., Badoor H. Performance Evaluation of a Multi-Agent System using Fuzzy Model // 1st International Workshop on Deep and Representation Learning (IWDRL), Cairo. 2018. P. 175–189.
8. Zaytsev E.I. Method of data representation and processing in the distributed intelligence information systems // Automation. Modern technologies. N 1. 2008. P. 29–34.
9. Red'ko V.G. Evolyutsiya, neyronnyye seti, intellekt: Modeli i kontseptsii evolyutsionnoy kibernetiki. Moscow : LIBROKOM. 2013. 224 s. (in Russian).
10. Graesser L., Keng W.L. Foundations of Deep Reinforcement Learning. Addison-Wesley Professional. 2020. 416 p.
11. Raj S., Ananthi J. Recurrent neural networks and nonlinear prediction in support vector machines // Journal of Soft Computing Paradigm (JSCP). 2019. V. 1, N 1. P. 33–40.
12. Batouma N., Sourrouille J. Dynamic adaption of resource aware distributed applications // International journal of grid and distributed computing. 2011. V. 4, N 2. P. 25–42.
13. Nurmatova E.V., Gusev V.V., Kotliar V.V. Analysis of the features of the optimal logical structure of distributed databases // Collection of works the 8th International Conference «Distributed Computing and Grid-technologies in Science and Education». Dubna, 2018. 167 p.
14. Sizov V.A., Kirov A.D. The development of models of an analytical data processing system for monitoring information security of an informatization object using cloud infrastructure // Russian Technological Journal. 2021. V. 9, N 6. P. 16–25. (in Russian).

В.Е. КУРЬЯН
ООО «АиС», Москва
kuryan@phystech.edu

МОДЕЛИРОВАНИЕ ПРОЦЕССА ОБУЧЕНИЯ ЧЕЛОВЕКА. АКСИОМАТИЧЕСКИЙ ПОДХОД

Описано построение системы автоматического перевода, моделирующей обучение человека. Обучение системы состоит в автоматическом построении модели мира в виде графа на основе анализа параллельных текстов. Правила построения графа заданы в виде аксиом обучения, не зависящих от конкретных языков. Использование модели мира приводит к объяснимости при получении результатов работы системы автоматического перевода.

Ключевые слова: *дерево модели мира, машинный перевод, аксиомы обучения.*

Введение

Задача автоматического перевода с одного естественного языка на другой является одной из наиболее сложных для систем искусственного интеллекта. В то же время это одна из наиболее общих задач. Существует несколько различных подходов к решению этой задачи. Первый основан на использовании синтаксического анализа текста и грамматических правил [1]. Второй – на статистическом подходе, когда сочетание слов переводится наиболее вероятным способом на основе предварительного статистического анализа корпуса обучающих текстов [2]. Третий использует нейронные сети для получения перевода [3, 4]. Четвертый использует метод аналогий, когда для перевода нового предложения используется похожее, перевод которого известен и которое отличается не сильно от текущего [5]. Пятый подход использует модель мира на основе онтологий [6]. Каждый из подходов имеет свои преимущества и недостатки. В настоящей работе предложен новый способ автоматического построения модели мира на естественном языке и использование этой модели для перевода текстов с одного естественного языка на другой. Такой подход позволяет сочетать в себе преимущества первого, второго, четвертого и пятого подходов. Наш подход имитирует мышление человека при познании мира. При обучении человек выделяет общие закономерности и особенности каждой конкретной ситуации и производит обобщения. Постро-

енная на таком принципе система будет обладать свойством объяснимости.

Основная идея автоматического перевода на основе модели мира на естественных языках состоит в том, что одна и та же ситуация во внешнем мире описывается на различных естественных языках и эти описания называются переводами с одного языка на другой. Перевод осуществляется следующим образом: по входному тексту, описывающему некоторую ситуацию в реальном мире на входном языке, выбирается часть модели мира, соответствующая этому тексту. В качестве перевода на выходной язык выбирается описание этой же части модели мира, но уже на выходном языке. Более детально алгоритм перевода описан в предыдущих работах автора [7–10]. В этих работах были проиллюстрированы процессы построения модели мира и ее использование для автоматического перевода. Настоящая работа посвящена аксиоматической формулировке алгоритма автоматического построения модели мира.

Аксиомы обучения переводу

Построение модели мира основывается на индуктивном подходе к познанию мира, изложенному Френсисом Бэконом в «Новом органоне». Алгоритм выделяет общие закономерности в обучающих текстах и производит обобщения. Основная идея автоматического построения модели мира состоит в том, что рассматриваются две ситуации во внешнем мире, имеющие нечто общее. Эти ситуации описываются на входном и выходном языках. Общей части этих двух ситуаций во внешнем мире соответствует общая часть в описании на входном и выходном естественных языках соответственно. Эти общие части на входном и выходном языках выделяются, и предполагается, что общей части на входном языке соответствует общая часть на выходном языке. Иными словами, переводом общей части на входном языке служит общая часть на выходном языке. Аналогично, различающимся частям ситуаций внешнего мира соответствуют различные части описаний на каждом из языков. При этом можно установить соответствие (перевод) между этими различающимися частями на входном и выходном языках. Этот подход соответствует переводу методом аналогий. В нашем подходе делается следующий шаг – построение иерархической модели, в которой выделение общих фрагментов во внешнем мире и их описаниях на входном и выходном языках соответствует выделению общих понятий и закономерностей внешнего мира. Далее мы можем работать с выделенными фрагментами как с самостоятельными ситуациями во внешнем мире и их описаниями на входном и

выходном языках. Это соответствует выделению обобщенных понятий и дальнейшей работе с ними.

Уточним постановку задачи построения графа модели мира. Будем считать, что во входном и выходном естественных языках имеется конечное число слов и словоформ (для простоты считаем все различные словоформы различными словами). Описание входной и выходной ситуаций представляет собой упорядоченный набор слов. Это может быть одно или несколько предложений. Будем считать, что токенизация описаний ситуации уже проведена. Каждому токenu (слову языка) соответствует его номер в некотором словаре, и далее мы работаем с описанием ситуации во внешнем мире, представленной в виде упорядоченного набора чисел (номеров слов или токенов в некотором словаре). Такое описание далее будем называть выражением на входном и выходном языках соответственно. Выражения на входном языке будем обозначать ENum, на выходном EOnum от слова выражение (expression), I (input) – входной язык, O (output) – выходной язык, num – некоторый числовой или буквенный индекс, нумерующий различные выражения.

Любое выражение может состоять из упорядоченного набора других выражений (элементов) более низкого уровня иерархии. В частности, выражение может представлять собой упорядоченную последовательность одного или несколько упорядоченных чисел. Эту упорядоченную последовательность чисел (выражение) можно группировать различными способами, получая различные представления исходного выражения в виде упорядоченной последовательности различных подвыражений. Так, к примеру, выражение (1, 2, 3) можно представить различными способами ((1,2), (3)) и ((1), (2,3)). Выражения удобно представлять в виде графа, в котором каждому выражению соответствует вершина, вершины более низкого уровня соответствуют элементам исходного выражения. Эти вершины соединены ребрами с вершиной исходного выражения. Различными вариантам представления исходного выражения соответствуют различные графы, как показано на рис. 1.




Рис. 1. Графическое представление различных вариантов разбиения выражения

Построение системой модели мира в виде графа происходит автоматически в процессе обучения. Обучение состоит в подаче системе пар выражений на входном и выходном языках, описывающих одну и ту же ситуацию во внешнем мире. Система сравнивает полученную информацию с уже имеющейся моделью мира и при необходимости производит изменения в текущей модели (в текущем графе) по определенным правилам. Эти правила будем называть аксиомами обучения.

Первая аксиома обучения A1 (которая фактически является определением понятия перевод) выглядит так. Пусть есть два выражения EI и EO на входном и выходном языках, описывающие одну и ту же ситуацию во внешнем мире, тогда переводом EI является EO. Следует отметить, что если EO является переводом EI, то и EI является переводом EO. В символическом виде это можно записать следующим образом: из [EI;EO] следует, что $EI \rightarrow EO$ и $EO \rightarrow EI$, где [EI;EO] означает, что даны два выражения на входном и выходном языке, описывающие одну и ту же ситуацию, $EO \rightarrow EI$ означает, что EI является переводом EO.

Вторая аксиома обучения A2. Пусть дано [(EI1,EI2);(EO1,EO2)] и [(EI1,EI3);(EO1,EO3)], тогда $EI1 \rightarrow EO1$, $EI2 \rightarrow EO2$, $EI3 \rightarrow EO3$. Аналогичные соответствия устанавливаются для случаев, когда общие фрагменты на обоих языках расположены в конце выражения и для тех случаев, когда на одном из языков общие фрагменты стоят в начале, а на другом в конце выражений. В качестве иллюстрации приведем пример пары выражений на русском и английском языках.

Петя ходит в зоопарк. Петя ходит в кино.

Pit goes to the zoo. Pit goes to the cinema.

В этом примере EI1=«Петя ходит в», EI2=«зоопарк», EI3=«кино», EO1=«Pit goes to the», EO2=«zoo», EO3=«cinema». Здесь мы для наглядности в качестве выражения выписываем их представление на естественном языке, а не номера слов (токенов) в словаре. Из аксиомы A2 следует, что переводом выражения «Петя ходит в» на входном языке является выражение «Pit goes to the» и, соответственно, «зоопарк» $\rightarrow$ «zoo», «кино» $\rightarrow$ «cinema». Как видим, из приведенного примера выражения EI1 и EO1 могут иметь разные длины. Как переводятся фрагменты выражений EI1 по имеющейся информации и аксиоме A2, установить невозможно.

Аксиома A2 выявляет наличие некоторой структуры выражений в модели мира в приведенном примере. На первом месте стоит некоторое подвыражение, а на втором месте может располагаться одно из нескольких различных выражений, для каждого из которых известен перевод. Логично выделить эти несколько различных выражений в некоторую новую

обобщающую сущность более высокого уровня иерархии – одинаково употребляющиеся слова или выражения. В нашем случае это «зоопарк» и «кино». В процессе дальнейшего обучения эта новая сущность может дополняться новыми словами и выражениями, к примеру, такими словами как «кафе», «ресторан», «парк» и т.п. или выражениями типа «плавательный бассейн» и т.п. Эта новая сущность одинаково употребляемых слов или выражений является просто множеством тех подвыражений, которые могут стоять в соответствующем месте выражения более высокого уровня иерархии.

Модель мира удобно представлять в виде иерархического графа, вершины которого соответствуют выражениям или обобщенным понятиям (одинаково употребляющихся слов или выражений). Поскольку выражение представляет собой упорядоченную последовательность подвыражений, то выражениям соответствуют вершины, несущие информацию о порядке следования подвыражений. Такие вершины будем называть структурными вершинами. Такие вершины несут информацию об общей структуре соответствующего естественного языка. Например, в английском языке в утвердительном предложении на первом месте всегда стоит подлежащее (субъект), на втором месте сказуемое (действие, которое совершает субъект) и т.д. В качестве субъекта может быть какой-либо человек (Петя, Коля, Василий и т.п.), а в качестве действия какой-то глагол (ходит, бежит, прыгает, ездит и т.п.). Вершины, описывающие множество одинаково употребляемых выражений, будем называть вершинами конкретизации. Выбор и подстановка определенного выражения из всего множества одинаково употребляемых выражений фиксирует конкретную ситуацию из множества похожих.

На языке графа модели мира аксиома A2 и выделение обобщенной сущности может быть описана преобразованием графа, приведенного на рис. 2. В левой части рисунка приведены графы на входном языке, а в правой половине – на выходном языке. Для приведенного выше примера на рисунке имеем $I = 2, j = 1$ (одинаковая часть выражений находится в начале), на входном языке вершине W8 соответствует «Петя ходит в», вершине W7 – «зоопарк», вершине W9 – «кино» и соответствующие выражения на выходном языке.

Новой обобщенной сущности соответствует вершина W10. Это вершина конкретизации. Ей соответствует множество мест, в которые может ходить Петя. При продолжении обучения получившиеся ранее структурные вершины и вершины конкретизации могут образовывать новые обобщенные понятия. На входном и выходном языках могут получаться

графы, имеющие различное число вершин и различную структуру. Их структура зависит от структуры входного и выходного языков, для которых строятся модели внешнего мира.




Рис. 2. Графическое представление аксиомы A2 и выделения обобщенной сущности

Графическое представление модели мира

Для решения задачи автоматического перевода используется представление модели мира на входном и выходном языках в виде графов с вершинами разных типов с установленными связями между этими графами. Граф описания модели мира представляет собой иерархическую структуру с вершинами трех типов для каждого входного и выходного языков. Вершины соединены между собой ссылками трех типов. Ссылки на более высокий уровень будем называть ссылками U (UP) типа, ссылки на более низкий уровень будем называть ссылками D (Down) типа, ссылки на часть графа на другом языке (на перевод) будем называть ссылками T (TRANSLATE) типа. Каждой ссылке U типа соответствует ссылка D типа, соединяющая ту же пару вершин в обратном направлении, и каждой ссылке D типа соответствует ссылка U типа. Аналогичным образом каждой ссылке T типа соответствует ссылка T типа, идущая в обратном направлении. Ссылки U и D типов соединяют вершины графа, соответствующие одному и тому же языку описания, ссылки T типа соединяют вершины модели, соответствующие разным языкам описания. Вершины графа бывают трех типов. Вершина S типа (структурная, обозначена се-

рым цветом) содержит информацию о порядке следования ссылок D типа на нижележащие вершины. Этот тип вершин может иметь сколько угодно ссылок каждого типа. Вершины K типа (конкретизации, обозначены темно-серым цветом) содержат информацию о том, какие нижележащие вершины могут попадаться в описании конкретной ситуации на данном месте. Эти вершины так же могут содержать произвольное число ссылок каждого типа. Порядок ссылок для этого типа вершин значения не имеет. Вершины P типа (подстановки обозначены светло-серым цветом) имеют ровно одну ссылку U типа и одну ссылку D типа. Ссылка U типа из вершины P типа указывает на вершину S типа или K типа, а ссылка D типа может указывать либо на вершину S типа, либо на вершину K типа.

Аксиомы построения модели мира

Удобно аксиомы построения модели мира изображать графически. При этом будем задавать два графа – начальную структуру (фрагменты модели мира до применения соответствующей аксиомы обучения) и конечную структуру, которая получается при применении правил преобразования этой аксиомы. Они будут отображать правила преобразования модели мира графическим способом. В этой работе сосредоточимся на аксиоме STAK2 (Stady axiom 2). Цифра 2 в названии аксиомы означает, что правило работает при разделении исходных выражений на две части и является развитием **Второй аксиомы обучения A2** путем добавления правила выделения обобщенной сущности (одинаково употребляющихся выражений). Более сложные аксиомы, возникающие при делении выражений на три части будут рассмотрены в следующих работах. Эти аксиомы могут ускорить процесс обучения и уменьшить необходимый размер обучающего корпуса.

Рисунки 3 и 4 задают правило STAK2. Аксиома STAK2 применяется только в том случае, если ни одна из вершин $W7i1 \dots W7ip$ не совпадает ни с одной из вершин $W9i1 \dots W9ig$ в графе на входном языке и нет аналогичных совпадений в дереве на выходном языке. На рисунке для краткости не показаны ссылки T типа между исходными графами на входном и выходном языках. Индексы I и O (входной и выходной языки) так же опущены для краткости. В левой части рисунка расположена часть графа на входном языке, а в правой части на выходном. Если $q = 1$, то вершины $W8$ и $WP8$ не создаются. Не создаются аналогичные вершины и при $p=1$, $r = 1$, $m=1$, $s = 1$, $v = 1$.

Проиллюстрируем применение правила STAK2 для следующей пары обучающих примеров [7, 8].




Рис. 3. Представление исходных выражений с общей одинаковой частью на входном и выходном языках




Рис. 4. Результат применения аксиомы STAK2

Петя ходит в магазин. Коля ходит в магазин.
Pit goes to the shop. Nick goes to the shop.

Исходный граф показан на рис 5. После выполнения преобразования по правилу STAK2 получается граф, показанный на рисунке 6.




Рис. 5. Исходный граф модели мира для двух пар обучающих выражений




Рис. 6. Граф модели мира после выполнения преобразования по правилу STAK2

Если мы введем еще похожую пару обучающих предложений:

Сергей ходит в магазин,

Sergey goes to the shop,

то после соответствующих преобразований получится похожий граф модели мира, в котором в вершинах 17 добавится ссылка D-типа, указывающая на слово Сергей (Sergey) на соответствующих языках, и между этими вершинами будет установлена ссылка T типа (перевод).

Следует отметить, что за счет обобщений исходные выражения представляются в более компактном виде (в виде более коротких выражений, содержащих обобщенные понятия). Это приводит к тому, что при работе алгоритма используются короткие выражения, поэтому для обучения достаточно небольшого числа обучающих примеров.

Правила построения модели мира не зависят от выбора конкретных языков и поэтому с одинаковым успехом работают для любых языков. Построенная таким способом модель обладает свойством объяснимости,

так как на каждом этапе построения понятно, почему проведено конкретное преобразование графа модели мира.

Выводы

В настоящей работе предложен аксиоматический подход к построению эффективной системы автоматического перевода с одного естественного языка на другой. Перевод основан на использовании модели мира на естественных языках. Построение модели мира в виде графа осуществляется автоматически в процессе обучения на основе правил (аксиом обучения). Процесс обучения состоит в подаче на вход системы пар выражений на входном и выходном языках. Алгоритмы обучения и перевода не зависят от выбора конкретных естественных языков. Построенная модель обладает свойством объяснимости.

Список литературы

1. Марчук Ю. Проблемы машинного перевода. Москва : Наука. 1982. 233 с.
2. Cho K. Learning Phrase Representations using RNN Encoder-Decoder for Statistical Machine Translation // arXiv preprint arXiv:1406.1078v. 2014.
3. Sutskever I., Vinyals O., Quoc V. Le Sequence to Sequence Learning with Neural Networks // arXiv preprint arXiv:1409.3215. 2014.
4. Kocmi T., Machacek D., Bojar O. The reality of multi-lingual machine translation // arXiv preprint arXiv:2202.12814. 2022.
5. Nagao M. A framework of a mechanical translation between Japanese and English by analogy principle // Artificial and Human Intelligence. Elsevier Science Publishers. In: A. Elithorn and R. Banerji (ed.). 1984. P. 173–180.
6. Анисимович К. и др. Синтаксический и семантический парсер, основанный на лингвистических технологиях abbuu compreno // Компьютерная лингвистика и интеллектуальные технологии. Труды XVIII Международной конференции "Диалог 2012": в 2-х томах. 2012. С. 91–103.
7. Курьян В.Е. Моделирование процесса обучения человека с помощью построения графа модели мира // Учет и статистика. № 4(56). 2019. С. 67–81.
8. Курьян В.Е. Алгоритм автоматического перевода текстов с помощью дерева модели мира // Учет и статистика. №1(57). 2020. С. 75–84.
9. Курьян В.Е. Автоматический перевод и граф модели мира // Применение технологий виртуальной реальности и смежных информационных систем в междисциплинарных задачах FIT-M 2020: сборник тезисов международной научной конференции. 2020. С. 305–309.
10. Курьян В.Е. Автоматический перевод на основе графа модели мира // Нейроинформатика-2021. XXIII Международная научно-техническая конференция. Сборник научных трудов. Москва : МИФИ. 2022. С. 29–38.

А.И. САМАРИНА, А.А. КОРЧИГИН

Санкт-Петербургский политехнический университет Петра Великого
alencombo@gmail.com

АВТОМАТИЗАЦИЯ ГИСТОЛОГИЧЕСКИХ ИССЛЕДОВАНИЙ ДЛЯ ВЫЯВЛЕНИЯ РАННЕЙ ОНКОЛОГИЧЕСКОЙ ПАТОЛОГИИ ГРУДИ

В статье описывается автоматизация гистологических исследований для выявления ранней инвазивной протоковой карциномы молочной железы с помощью свёрточной нейронной сети. Предмет исследования – гистологические снимки тканей молочной железы, классифицированные по признакам «здоровая ткань» и «раковая ткань». В данной работе сравнивалось трансферное обучение моделей, основанных на нейронных сетях EfficientNetB7, InceptionResNetV2, VGG19. Наилучшие результат обучения показала модель, основанная на EfficientNetB7, она была выбрана для интеграции в программно-аппаратный комплекс.

Ключевые слова: *нейронные сети, инвазивная протоковая карцинома, машинное обучение, рак молочной железы, свёрточные нейронные сети, efficientnetb7, inceptionresnetv2, vgg19.*

Введение

Рак молочной железы – один из самых распространенных видов рака среди женщин среднего возраста в мире, 70% из которых инвазивная протоковая карцинома (IDC) и заболеваемость которой значительно возросла за последние 20 лет [1]. В 2018 году во всем мире было зарегистрировано 2,1 миллиона новых случаев рака молочной железы [2]. Если рак молочной железы можно диагностировать и лечить на ранних сроках, выживаемость больных может быть увеличена до 80% [3].

Медицинские технологии визуализации быстро развиваются в последнее время, но патологический анализ биопсии ткани по-прежнему остается золотым стандартом для окончательной диагностики [4, 5]. В патологическом анализе ткани рака молочной железы образец ткани, взятый пункцией или хирургическим путем, окрашивается гематоксилином и эозином (H&E). Ядро окрашивается гематоксилином в пурпурный цвет, цитоплазма окрашивается красным эозином [6]. Установление диагноза патологоанатомом – процесс трудоёмкий и достаточно субъективный, потому что зависит от опыта специалиста. Средняя точность составляет

около 75% [7].

С появлением цифровых сканеров гистопатологические образцы сканируются в полное изображение слайда (WSI) и сохраняются на компьютере в цифровом виде, что обеспечивает основу для автоматического количественного анализа [8].

Свёрточные нейронные сети (CNN) добились отличных результатов в области анализа медицинских изображений [9], поэтому компьютерная диагностика может упростить процесс, автоматически анализируя области ткани IDC в WSI рака молочной железы, обеспечивая объективную оценку для патологоанатомов. Поэтому данная работа имеет важное исследовательское значение для раннего выявления IDC и его лечения.

Целью данной работы является автоматизация гистологических исследований для выявления ранней инвазивной протоковой карциномы молочной железы с помощью свёрточной нейронной сети.

Задачи:

1. Выбор набора изображения данных.
2. Обучение свёрточных нейронных сетей на выбранном наборе.
3. Сравнение результатов, полученных от нейронных сетей.
4. Выбор обученной нейронной сети для дальнейшего взаимодействия с программными комплексами.

Аналитический обзор гистологических исследований молочной железы

Грудь человека представляет собой парные молочные железы, расположенные на передней и частично на боковых сторонах грудной клетки.

Основные патологии груди связаны с железистой тканью: они могут быть доброкачественного и злокачественного характера. Один из самых распространенных типов – инвазивная протоковая карцинома, являющаяся злокачественным образованием, но подлежащая лечению при своевременном обнаружении.

Выяснить природу патологии помогают методы световой и электронной микроскопии.

Визуализация всего предметного стекла (WSI) или виртуальная микроскопия – это сканирование стеклянных предметных стекол для создания цифровых слайдов, на данный момент является самым современным методом электронной микроскопии.

WSI открывает широкие возможности для машинного обучения, но имеет ряд проблем: большая размерность изображений, недостаточное количество обучающих выборок, вариативность окрашивания в разных

лабораториях, извлечение клинически значимых признаков и информации.

Нейросетевой метод обработки изображений и его применение

Искусственная нейронная сеть (ANN) создана на основе механизма работы нервной системы человека. Глубокие нейронные сети (DNN) принадлежат к семейству ANN. Они состоят из множества скрытых слоев между входным и выходным слоями.

Сверточные нейронные сети (CNN) относятся к семейству нейронных сетей в области глубокого обучения. Они обычно используются для визуальной обработки изображений.

DNN, особенно CNN, широко используются в изменяющихся задачах классификации изображений и достигли значительной производительности. Некоторые исследования по классификации медицинских изображений, проведенные CNN, достигли результатов, конкурирующих с экспертами-людьми. Поэтому глубокая нейронная система на основе CNN широко используется в задаче медицинской классификации.

Трансферное обучение – это область машинного обучения и искусственного интеллекта, целью которой является применение знаний, полученных из исходной задачи, к целевой задаче. Основополагающая трансферного обучения – предобученная модель. Предобученная модель – это модель, созданная и обученная кем-то другим для уже существующей задачи. Хорошие результаты в обработке медицинских изображений показали предобученные нейронные сети семейств VGG, InceptionResNet, EfficientNet.

Поэтому, изучив нейросетевой подход к автоматизации медицинских изображений, был выбран подход трансферного обучения с последующей настройкой последних слоев предобученных нейронных сетей, таких как: VGG19, InceptionResNetV2, EfficientNetB7.

Наборы изображений для автоматизации гистологических исследований

Исходный набор данных для обучения взят с сервиса Kaggle и загружен представителем Института рака Рутгерса в Нью-Джерси. Датасет состоит из 162 полных изображений слайдов образцов рака молочной железы, отсканированных с увеличением 40х.

Из 162 полных изображений слайдов было извлечено 277 524 участка (198 738 отрицательных IDC и 78 786 положительных IDC) размером 50*50.

Имя файла каждого патча записывается в формате «u xX yY classC.png», где u – идентификатор пациента, X – координата по оси x того места, откуда была вырезана эта накладка, Y – координата по оси y, откуда была вырезана эта накладка, а C указывает класс, где 0 – это здоровая ткань и 1 – раковая ткань (рис. 1). Пример записи: 10253 idx5 x1351 y1101 class0.png

Датасет имеет лицензию «CC0 1.0 универсальный: общественное достояние»




Рис. 1. Классы патчей: 0 – Здоровая ткань, 1 – раковая ткань

Алгоритм обучения нейронной сети

Алгоритм обучения нейронной сети состоит из нескольких этапов: предобработка датасета, настройка параметров обучения, обучение, получение результатов и сохранение модели.

Так как за основу были взяты предобученные нейронные сети, то алгоритм работы будет выстраиваться с трансферным обучением:

1. Предобработка датасета.
2. Настройка параметров обучения.
3. Обучение.
4. Получение и сохранение результатов.

Результаты обработки изображений

Ресурсы: облачные мощности платформы Kaggle, GPU: NVIDIA TESLA P100.

Стек: язык программирования Python, фреймворк TensorFlow.

Библиотеки: *keras*, *matplotlib*, *numpy*, *tqdm*, *pandas*.

Для каждой нейронной сети, согласно алгоритму, были заданы свои значения параметров. Подбор значений проводился 20 итерациями для каждой нейронной сети, затем, относительно метрик, выбирался наилучший результат.

Таблица 1

Параметры моделей

	VGG19	InceptionResNetV2	EfficientNetB7
Размер входного изображения, пиксели	224*224	75*75	75*75
Оптимизатор	Adam: 0,00001	Adam: 0,001	Adam: 0,001
Функция потерь	бинарная кросс-энтропия	бинарная кросс-энтропия	бинарная кросс-энтропия
Функция активации	сигмоида	сигмоида	сигмоида
Основные метрики	precision, recall, AUC, f1-score	precision, recall, AUC, f1-score	precision, recall, AUC, f1-score
Количество эпох	10	8	4
Слои	функциональный слой VGG19 и полносвязный слой	функциональный слой InceptionResNetV2 и полносвязный слой	функциональный слой EfficientNetB7, операционный слой и полносвязный слой

Таблица 2

Отчет основных метрик для модели, основанной на VGG19

	precision	recall	f1-score	support	AUC
cancer	0,84	0,84	0,84	1189	0,83460
healthy	0,84	0,84	0,84	1153	
accuracy			0,84	2342	
macro avg	0,84	0,84	0,84	2342	
weighted avg	0,84	0,84	0,84	2342	

Таблица 3

Отчет основных метрик для модели, основанной на InceptionResNetV2

	precision	recall	f1-score	support	AUC
cancer	0,87	0,84	0,86	1240	0,86007
healthy	0,85	0,88	0,86	1247	
accuracy			0,86	2487	
macro avg	0,86	0,86	0,86	2487	
weighted avg	0,86	0,86	0,86	2487	

Таблица 4

Отчет основных метрик для модели, основанной на EfficientNetB7

	precision	recall	f1-score	support	AUC
cancer	0,93	0,82	0,87	8000	0,94572
healthy	0,84	0,94	0,89	8000	
accuracy			0,88	160 00	
macro avg	0,89	0,88	0,88	160 00	
weighted avg	0,89	0,88	0,88	160 00	

Наилучшей моделью среди трех сравниваемых оказалась модель, основанная на EfficientNetB7. Ее AUC = 0,94572, precision avg = 0,89, recall avg = 0,88, f1-score = 0,88, что показывает достаточно хорошую работу модели в классификации изображений.

При оценке результатов на тестовой выборке модель, основанная на EfficientNetB7, из 16 изображений показала недостоверно только одно изображение, на котором слабо прослеживалась раковая ткань. Таким образом, модель, основанная на EfficientNetB7, может являться хорошей программой, основанной на нейросетевом методе, для дальнейшей интеграции в программно-аппаратный комплекс, чтобы быть сервисом второго мнения.

Алгоритм программы для автоматизации гистологических исследований и ее реализация в аппаратно-программном диагностическом комплексе

В данном пункте мы рассмотрим алгоритм программы, которая может быть написана для обученной нейронной сети (рис. 2).

Алгоритм программы:

- 1. Загрузка изображений.** Получение изображений из WSI-сканнера или WSI-микроскопа в формате jpg или png. Сегментация изображения происходит на стороне программного обеспечения сканнера или микроскопа.
- 2. Обработка изображений**
 - 2.1. Масштабирование изображения до размеров 75*75 пикселей, увеличение параметра резкости, загрузка файла в нейронную сеть.
 - 2.2. Сохранение координат патча из имени файла в базу данных.



Рис. 2. Алгоритм программы

3. Взаимодействие изображения с нейронной сетью

- 3.1. Вывод вероятности принадлежности изображения к одному из классов на экран программы.
- 3.2. Сохранение в базе данных вероятности принадлежности изображения к одному из классов.

4. Вывод общего результата. Загрузка из базы данных координатной сетки с распределёнными по ней вероятностями принадлежности патча к одному из классов.

Выводы

Для автоматизации гистологических исследований был выбран метод машинного обучения, использующий трансферное обучение предобученной нейронной сети, с последующим написанием алгоритма для интеграции в аппаратном комплексе.

1. Обучение проводилось в облачной среде Kaggle с использованием GPU на наборе данных гистопатологических исследований молочной железы, состоящих из 278 000 изображений здоровой и раковой ткани, с открытой лицензией.

2. Для выбора нейронной сети, которую будет использовать алгоритм для автоматизации исследования, использовалось сравнение трех предобученных нейронных сетей: VGG19, InceptionResNetV2, EfficientNetB7.

3. Результаты по метрике AUC оказались следующими: VGG19 – 0,83460, InceptionResNetV2 – 0,86007, EfficientNetB7 – 0,94572. Такой

результат можно объяснить тем, что поколение предобученных нейронных сетей EfficientNet является наиболее современным, а EfficientNetB7, выпущенная в 2019 году, учитывает в себе недочёты нейронных сетей более ранних моделей.

4. По показателю наибольшей точности, модель, основанная на трансферном обучении EfficientNetB7, может быть положена в основу алгоритма в аппаратном комплексе.

Современные аппаратные комплексы используют технологию WSI, которая помогает получать изображения высокого разрешения. Полученные изображения могут делиться на более маленькие изображения, называемые патчами, составляя единое изображение по координатной сетке. Такое деление помогает точно локализовать поражённые раком участки ткани. В написанном алгоритме анализ через нейронную сеть проходит за одну сессию один патч, в память записывается вероятность поражения раком и координата патча. На выходе мы получаем распределение массы координат и вероятности поражения на грудной клетке.

Программа, основанная на предложенном алгоритме, будет являться сервисом второго мнения. Она оказывает помощь врачу в установлении описании патча гистологии молочной железы.

В перспективе программа может быть масштабирована, добавлены функции очерчивания локализации нездоровых участков ткани. Также, для увеличения точности, можно провести ряд экспериментов с гибридной формой обучения.

Интерфейс может быть локальным, на персональном компьютере, так и с возможностью использования Интернета, например, вычисление из облачных серверов.

На данный момент в программу можно загружать только одно изображение. В потенциале программа может настраиваться на большее количество входных изображений за одну сессию. Отчёт можно будет получить в виде табличных данных или баз данных, что предоставит возможность оперировать большими данными для нужд здравоохранения и самой больницы.

Список литературы

1. Siegel R. L., Miller K. D., Jemal A. Cancer statistics // CA: A Cancer J. Clinicians. 2017. V. 67, N 1. P. 7–30.
2. Bray F., Ferlay J., Soerjomataram I., Siegel R.L., Torre L.A., Jemal A. Global cancer statistics 2018: GLOBOCAN estimates of incidence and mortality worldwide for 36 cancers in 185 countries // CA: A Cancer J. Clinicians. 2018. V. 68, N 6. P. 394–424.

3. Didkowska J., Wojciechowska U. WHO position paper on mammography screening // *Oncology in Clinical Practice*. 2015. V. 11, N 1. P. 16–19.
4. He L. Computer assisted diagnosis in histopathology // *Sequence Genome Anal., Methods Appl.* 2010. V. 3. P. 271–287.
5. He L., Long L.R., Antani S., Thoma G.R. Histology image analysis for carcinoma detection and grading // *Comput. Methods Programs Biomed.* 2012. V. 107, N 3. P. 538–556.
6. Romeny B.M.H. Frontend Vision and Multi-Scale Image Analysis: MultiScale Computer Vision Theory and Applications // *Written in Mathematica*. 2008. V. 27. Dordrecht, The Netherlands: Springer.
7. Aswathy M.A., Jagannath M. Detection of breast cancer on digital histopathology images: Present status and future possibilities // *Informat. Med. Unlocked*. 2017. V. 8. P. 74–79.
8. Spanhol F.A., Oliveira L.S., Petitjean C., Heutte L. Breast cancer histopathological image classification using convolutional neural networks // In: *Proc. Int. Joint Conf. Neural Netw. (IJCNN)*. 2016. P. 2560–2567.
9. Janowczyk A., Madabhushi A. Deep learning for digital pathology image analysis: A comprehensive tutorial with selected use cases // *J. Pathol. Informat.* 2016. V. 7, N 1. P. 29.

Я.А. СЕРЕДА, И.Д. НИКОНОВ, Ю.Д. ПРЕОБРАЖЕНСКАЯ

Нижегородский государственный университет им. Н.И. Лобачевского
sereda@itmm.unn.ru

МОДЕЛЬ ОБУЧЕНИЯ АГЕНТА, ОСНОВАННАЯ НА ЗАПОЛНЕНИИ КОГНИТИВНОЙ КАРТЫ*

Предлагается подход к обучению интеллектуальных агентов, при котором долговременная память агента хранит выученные программы действий. Показано, что при такой структуре памяти можно использовать классический аппарат тестирования статистических гипотез как математический аппарат обучения по нескольким образцам. Предлагаемый подход к обучению имеет биологические предпосылки.

Ключевые слова: *обучение по нескольким образцам, искусственный интеллект, статистические гипотезы.*

Введение

Несмотря на значительные успехи современных алгоритмов машинного обучения [1, 2], проблема стабильного обучения по нескольким образцам остаётся актуальной [3]. Для того чтобы справиться с этой проблемой, зачастую необходимо использовать сложные надстройки над базовыми алгоритмами обучения (например, метаобучение как надстройка над базовым алгоритмом глубокого обучения [4]). Целью данной работы является разработка подхода, при котором обучение на нескольких примерах работает «из коробки». В основу предлагаемого подхода легли несколько предпосылок из нейрофизиологии. Одна из них — это когнитивная карта.

Понятие когнитивной карты возникло в нейрофизиологии при изучении строения гиппокампа млекопитающих, ключевой ее частью являются нейроны решетки, задающие систему координат на местности [5]. Для нейронов решётки известно, что сигналы активации к ним поступают от

* Проект 0729-2021-013, выполняемый в рамках Государственного задания на выполнение научно-исследовательских работ лабораториями, прошедшими конкурсный отбор в рамках национального проекта «Наука и университеты», в отношении которых принято решение Бюджетной комиссии Минобрнауки России (от 14.09.2021 № БК-П/23) о предоставлении из федерального бюджета субсидии на финансовое обеспечение государственного задания на выполнение научно-исследовательских работ.

регистраторов собственных движений животного. Это говорит о том, что нейроны решетки можно рассматривать как нейроны, кодирующие действия (или классы действий, эквивалентных по результату), доступные животному.

В предлагаемом нами алгоритме обучения процесс распознавания сводится к совершению агентом последовательности экспериментов, результаты которых (события) регистрируются в структуре данных, аналогичной когнитивной карте. Понятия эксперимента и события, упомянутые выше, полностью совпадают с соответствующими понятиями из аксиоматики теории вероятностей: случайный эксперимент включает определение процедуры его проведения и множество его элементарных исходов, подмножества которого называют событиями.

Испытания предлагаемой концепции обучения были проведены на изображениях рукописных цифр. Такой выбор тестовых данных обусловлен следующим: в биологии существует предположение, что кора мозга в разных ее местах устроена примерно по одному и тому же закону [6]. Если это так, то все процессы распознавания должны работать по одному принципу. То есть структура, аналогичная когнитивной карте, должна возникать и при распознавании статической картинки, и при тактильном распознавании нового объекта, и при работе со всеми остальными типами данных [7].

В данной работе мы исходим из того, что планирование/проведение экспериментов является основой работы интеллекта. Это также согласуется с идеями из биологии [8, 9], где, например, считается, что процесс распознавания человеком статического изображения – это процесс конструирования и выполнения им последовательности экспериментов, основанных на сдвигах взгляда по сложным траекториям (см. саккады [10]).

Общее описание метода

В задаче распознавания изображений доступными агенту действиями являются сдвиги взгляда. Таким образом, когнитивная карта (в предлагаемом подходе) включает в себя все возможные сдвиги взгляда и представляет собой структуру данных, в которой сдвигу взгляда может быть сопоставлено сенсорное событие, если оно наблюдалось после данного сдвига. Процесс распознавания сводится к целенаправленному обнаружению «информационно ценных событий» (будет пояснено далее) и регистрации их на когнитивной карте по мере обнаружения, см. рис. 1.

Информационно ценным будем считать такое событие, которое статистически достоверно влияет на вероятности возникновения других собы-

тий в данной сессии распознавания. Рассмотрим, например, событие «обнаружен глаз» во время распознавания изображения. Это очень редкое событие.




Рис. 1. Сессия распознавания начинается с пустой когнитивной карты: агент ещё не провел ни одного эксперимента. Затем агент выполняет случайный эксперимент и регистрирует результат – событие e_1 . Затем агент снова проводит какой-то эксперимент и регистрирует событие e_2 и т.д.

Если в произвольной точке произвольного изображения попытаться «распознать глаз», то такой эксперимент почти всегда потерпит неудачу (глаза в данной точке не окажется). Однако если уже известно, что во время распознавания произошло событие «обнаружен рот», то ситуация меняется: теперь глаз будет обнаружен с большой вероятностью. Событие перестало быть редким. Для таких случаев мы будем говорить, что событие e_2 влияет на прогноз события e_1 . Событие тем более ценно, чем больше факт его наличия в контексте влияет на другие события (чем более драматичный пересчет текущих предсказаний оно вызывает).

Процедура распознавания состоит в том, чтобы обнаружить наиболее ценные события за наименьшее количество действий.

Организация долговременной памяти

В каждый момент процесса распознавания обученный агент сталкивается с вопросом – какой эксперимент выгодно провести следующим? Ответ на этот вопрос зависит от того, какие события уже отмечены на карте к этому моменту. Это диктует правило организации долговременной памяти: триггером, запускающим данный эксперимент, является возникновение в когнитивной памяти некоторого события, для которого доказано, что данный эксперимент является наиболее выгодным при условии наличия данного события (событий) в карте. Устройство памяти ассоциативно: эксперимент ведет к появлению нового события на карте, это событие запускает другой эксперимент, который добавляет еще событие на карту, которое, в свою очередь, запускает следующий эксперимент.

Обозначим $E(e_i)$ эксперимент, который может привести к сенсорному событию e_i . Например, если e_i является фактом распознавания глаза на фотографии, то $E(e_i)$ – это соответствующая сложная программа саккадического зрения.

Поскольку конкретный эксперимент может быть запущен только определенным событием, неизбежно оказывается, что долговременная память организована как графо-подобная структура, в которой «вершины» являются событиями, а «рёбра» – экспериментами. В таком случае процесс обучения сводится к обнаружению отношений между событиями и добавлению информации об этом в графо-подобную память.

Долговременная память в такой формулировке является растущей структурой и обучение сводится к определению правила роста для неё.

Правило роста — идея

Довольно часто в группе из нескольких событий (скажем, e_1 , e_2 , e_3) возникает интересный групповой эффект. Он занимает центральное место в нашем алгоритме обучения. Суть его в том, что два события вместе влияют на некоторое третье событие иначе, чем они бы повлияли на него по отдельности.

Рассмотрим пример распознавания лица. Здесь имеются три события: «левый глаз», «правый глаз», «нос» (рис. 2).




Рис. 2. Взаимодействие двух событий («левый глаз» и «правый глаз») через третье событие («нос») при распознавании лиц. Пояснения в тексте

Событие «левый глаз» является предиктором события «нос», но предсказание неточно. Оно включает в себя не конкретную координату, а целую область на когнитивной карте, где можно найти нос (отмечена серым на рис. 2). Событие «правый глаз» также является источником предсказания того, где будет ожидать событие «нос» (и дает ту же по размерам область на карте).

Но если события «левый глаз» и «правый глаз» присутствуют в контексте одновременно, то их совместное предсказание о событии «нос»

дает гораздо меньшую область на карте, и она не является пересечением предыдущих. Она не является их комбинацией какого-либо рода. Это происходит из-за симметрии лица.

Наличие такого отношения в этой тройке событий означает, что если на карте уже имеется событие «левый глаз», то выгода от эксперимента по поиску «правого глаза» состоит в прогнозируемом пересчете предсказаний о местоположении «носа». Это и обеспечивает ценность совершения попытки распознавать второй глаз, когда уже распознан первый. И чем сильнее вызываемый пересчет, тем ценнее такое объединение пары экспериментов («левый глаз», «правый глаз») в составной эксперимент (регистрирующий событие «пара глаз»).

Правило роста – формализация через механизм статистических гипотез

Пусть на карте есть два события e_i и e_j , и задача состоит в том, чтобы доказать, что по отдельности они влияют на результат некоторого эксперимента E иначе, чем вместе. Для этого нужно убедиться, что выборка $E | (e_i, e_j)$ отличается как от выборки $E | e_j$, так и от выборки $E | e_i$ (здесь «|» означает при условии).

В обоих случаях возникает классическая задача проверки гипотезы о том, что две выборки взяты из одного и того же распределения. Если различие (адекватное ситуации статистического критерия) оказывается *крайне малым*, то делается вывод, что выборки почти наверняка относятся к разным распределениям и, таким образом, доказана ценность проведения эксперимента, ведущего к событию e_j при наличии в контексте события e_i .

Условие надежности р-значений

Р-значения обычно нестабильны по отношению к регенерации выборок. В общем случае неясно, при каком минимальном размере выборки и какое р-значение достаточно мало, чтобы установить его порогом для надежного принятия решения [11]. Однако бывает ситуация, когда р-значения очень стабильны.

Пусть есть две монеты, описывающиеся параметрами p_1 и p_2 , и соответственно, две выборки s_1 и s_2 . Выбирается подходящий статистический критерий и решается задача проверки непараметрической гипотезы о том, что и s_1 , и s_2 взяты из одного и того же распределения. Оказывается, если $|p_1 - p_2|$ почти равно 1, то р-значения (даже на малых выборках) являются,

во-первых, сверхмалыми, а во-вторых, устойчивыми к регенерации выборки. Если же, наоборот, p_1 мало отличается от p_2 , то даже при достаточно больших выборках p -значения не стабильны. То есть предпосылкой надежных и сверхмалых p -значений при тестировании такой гипотезы является ситуация, когда очень редкое событие (в первой выборке) стало очень частым (во второй). Это интуитивно ожидаемо: если выборки отличаются очень сильно, то p -значения быстро становятся маленькими с ростом размера этих выборок.

Обучение по нескольким образцам (почему возникает в рамках предложенного подхода)

В предложенном подходе новые события создаются путем соединения существующих по схеме: «если произошло событие e_i , то запустить $E(e_j)$ и, если он завершился событием e_j , добавить в карту новое событие (назовем его e_k)». Очевидно, что e_k имеет меньшую вероятность успеха, чем породившие его события, просто потому что его вероятность является произведением их вероятностей. Таким образом, чем более многошаговый эксперимент порождает событие, тем более редким является это событие. Чем дольше идет обучение, тем больше именно редких событий выучивает агент.

Ситуация, которая запускает обучение, — это появление непредсказанного редкого события на когнитивной карте. Делается предположение, что это безусловно редкое событие вызвано комбинацией других событий из контекста. То есть в их присутствии это событие должно стать частым. Это предположение далее статистически проверяется. И если оно верно, то как раз и складывается ситуация, что что-то редкое (в одной выборке) стало частым (в другой). Что, в свою очередь, вызывает быстрое появление надежно малых p -значений с ростом этих выборок, описанное выше. И, следовательно, наличие взаимосвязи между событиями доказывается за несколько образцов. Это подтверждают наши эксперименты на MNIST.

Эксперименты на MNIST

В этой работе мы сначала опишем, как в ходе обучения появляется первая выученная сигнатура эксперимента, а затем приведем примеры обнаруженных взаимодействующих событий с более поздних шагов обучения.

Перед обучением в памяти агента имеется набор доступных действий (сдвиги взгляда dx , dy) и один сенсор S , который может измерять яркость в пикселе. Таким образом, у агента есть базовый набор элементарных экс-

периментов, каждый из которых полностью описывается следующим образом: $\langle dx, dy, S \rangle$. Множеством элементарных исходов любого такого эксперимента являются числа от 0 до 255, причем фон изображений состоит преимущественно из пикселей яркости 0.

Событие – это функция-индикатор поверх множества элементарных исходов эксперимента. Нас интересует вопрос о нахождении наиболее ценной индикаторной функции. Испытания показывают, что лучший индикатор – это: $f_0(s) = \begin{cases} 1, & s < 10, \\ 0, & s > 10, \end{cases}$

где s – элементарный исход. Обозначим это выученное событие e_0 . Для него статистически доказано влияние на, по крайней мере, четыре экспе-

римента: $\langle dx = 0, dy = 1, S \rangle$, $\langle dx = 0, dy = -1, S \rangle$, $\langle dx = 1, dy = 0, S \rangle$, $\langle dx = -1, dy = 0, S \rangle$ (это сдвиги взгляда в соседние пиксели от данного).

Полученный результат очень интуитивен: событие e_0 отделило фон от не фона. Предсказательная ценность оказалась обеспечена соседними пикселями, что тоже интуитивно понятно.

Наши численные тесты показывают, что на данном этапе обучения (когда в памяти еще нет сложных экспериментальных программ) невозможно доказать взаимодействие между двумя очень далекими экземплярами e_0 . Возможно лишь между довольно близкими. При этом в ходе обучения возникают детекторы фрагментов наклонных линий разного наклона.

На более поздних этапах обучения появляется программа экспериментов, которая «обнаруживает» полукольцо при обучении агента на рукописных тройках. Она состоит из нескольких шагов. В случае, когда все шаги завершились ожидаемыми событиями, программа считается завершённой успешно и добавляет в контекст новое событие e_s в соответствующем месте когнитивной карты (см. рис. 3).

На рис. 3 показано, что событие e_s является редким (количество отмеченных точек мало по сравнению с размером изображения). И именно его редкость позволяет доказать через него связь между другими событиями за малое количество примеров (см. рис. 4).

Аналогично, в ходе обучения доказывается и взаимодействие этих двух событий ($e_0^{(1)}$ и $e_0^{(2)}$ из рис. 4) через экземпляр события e_s в области нижнего полукольца. Таким образом, в процессе обучения формируется

интерпретируемая концепция рукописной тройки.



Рис. 3. Отмечены точки, при запуске из которых выученный эксперимент $E(e_s)$ заканчивается успехом. Для целей визуализации программа $E(e_s)$ запускалась из каждого пикселя изображения. Видно, что успех не был достигнут в подавляющем большинстве пикселей, поэтому e_s – это выученное редкое событие




Рис. 4. События, $e_0^{(1)}$ и $e_0^{(2)}$, взаимодействуют через событие e_s , соответствующее программе, распознающей полукольцо. Ромбом показана область допустимого положения события e_s на когнитивной карте, для которой велось доказательство. В ходе тестирования гипотез возникли сверхнизкие р-значения в обеих гипотезах (менее 0,00001 в обеих гипотезах при размере выборок в 20 экземпляров)

Заключение

Был предложен подход к машинному обучению, который во многом похож на обучение последовательности условных рефлексов.

Полезным следствием предложенного подхода к обучению является то, что топологию сети не нужно предварительно указывать, как это делается во многих других подходах (например, в сетях глубокого обучения или графических вероятностных моделях). На каждом новом образце входных данных обучается не вся сеть, а только небольшая часть. Это соотносится с нашими знаниями о мозге, а также приводит к невозможности феномена катастрофического забывания [12] в такой сети: если в данных обнаруживается новый паттерн, это просто вызывает добавление новых записей в память агента.

Список литературы

1. Jumper J. [et al.]. Highly accurate protein structure prediction with AlphaFold // Nature. 2021. V. 596, N 7873. P. 583–589.
2. Karras T., Laine S., Aila T. A style-based generator architecture for generative adversarial networks // Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. 2019. P. 4401–4410.
3. Parnami A., Lee M. Learning from Few Examples: A Summary of Approaches to Few-Shot Learning // arXiv preprint arXiv:2203.04291. 2022.
4. Huisman M., Van Rijn J.N., Plaat A. A survey of deep meta-learning // Artificial Intelligence Review. 2021. V. 54, N 6. P. 4483–4541.
5. O'keefe J., Nadel L. The hippocampus as a cognitive map. Oxford university press. 1978.
6. Hawkins J. [et al.]. A framework for intelligence and cortical function based on grid cells in the neocortex // Frontiers in neural circuits. 2019. V. 12. P. 121.
7. Long X., Zhang S.J. A novel somatosensory spatial navigation system outside the hippocampal formation // Cell research. 2021. V. 31, N 6. P. 649–663.
8. Friston K. [et al.]. Perceptions as hypotheses: saccades as experiments // Frontiers in psychology. 2012. V. 3. P. 151.
9. Cook C., Goodman N.D., Schulz L.E. Where science starts: Spontaneous experiments in preschoolers' exploratory play // Cognition. 2011. V. 120, N 3. P. 341–349.
10. Yarbus A.L. Eye movements and vision. Springer. 2013.
11. Nuzzo R. Scientific method: Statistical errors // Nature. 2014. V. 506. P. 150–152.
12. Kemker R. [et al.]. Measuring catastrophic forgetting in neural networks // Proceedings of the AAAI Conference on Artificial Intelligence. 2018. V. 32, N 1.

В.С. СМОЛИН¹, Д.В. ЖУРАВЛЕВ²

¹Федеральный исследовательский центр Институт прикладной математики
им. М.В. Келдыша РАН, Москва

²DIGITALMS, Data Management Service

¹smolin@keldysh.ru, ²d.zhuravlev@digitalms.ru

**ТЕОРИИ ПОЗНАНИЯ, СОЗНАНИЯ, ЭМОЦИЙ И ПРОЧИХ
«ЧЕЛОВЕЧЕСКИХ» СВОЙСТВ ДЛЯ РОБОТОВ**

Многомерные аппроксимации, осуществляемые современными нейросетевыми алгоритмами, уже позволили решить широкий круг прикладных задач. Представляется, что осуществление декомпозиции сложных задач и иерархическое представление знаний в нейросетях (по подобию действий человека) позволит заметно ускорить обучение нейросетей и продвинуться в область ещё более сложных задач. Даже предварительный анализ свойств работы иерархической структуры представления знаний на основе аппроксимации и декомпозиции позволяет по-новому взглянуть на такие понятия, как познание, сознание и эмоции.

Ключевые слова: *знания, нейросети, сознание, эмоции.*

Введение

Эффективность нейросетевых алгоритмов основана на способности в процессе своей работы настраивать огромное количество параметров для улучшения действий при решении поставленной задачи. Действительно, как было доказано в [1], необходимая сложность систем для решения «интеллектуальных» задач должна соответствовать сложности задач.

Но основной современный путь развития нейросетевых алгоритмов, связанный с увеличением числа параметров обучения и «глубины» нейросетевых структур, подвергается обоснованной критике даже со стороны «отцов-основателей» глубокого обучения [2].

Необходимо искать пути более быстрого обучения нейросетей и использования ранее полученных знаний для решения новых задач. По мнению авторов, основным направлением реализации этих путей является формирование иерархических декомпозиций знаний и использование мультирежимности при работе нейросетевых структур.

Знания и свойства

Входные и выходные данные, знания – всё это (и многое другое) можно описать последовательностями нулей и единиц и несёт в себе инфор-

мацию, которую принято определять как минимальное представление данных, необходимое для снятия неопределённости. Минимизация представления данных – важная техническая проблема, решение которой позволяет оптимизировать работу многих информационных устройств. Но задача создания знаний для формирования на их основе выходных данных теорией информации не рассматривается, а решается человеком. Здесь мы хотим рассмотреть именно эту сторону преобразования входных данных в выходные: как можно создавать знания без участия человека-разработчика.

Определение: термин «знания» будем понимать в широком смысле, как любую информацию, содержащуюся в системе управления и используемую для преобразования входных данных в выходные (рис. 1)




Рис. 1. Схема формирования выходных данных и новых знаний на основе имеющихся знаний и данных из внешней среды

При таком определении «знаний» любое устройство, преобразующее входные данные в выходные, обладает некоторыми знаниями, содержащимися в его структуре и в памяти (при наличии).

В принципе, любое внешнее воздействие можно рассматривать как входные данные, а реакцию на них – как выходные данные. Но если объект прост и не способен на проявление разнообразных реакций на входные воздействия, то правильнее говорить про свойства, а не знания такого объекта. Например, шарик или вода всегда скатятся вниз с плоской наклонной поверхности, но это их свойства, а не знания. Хотя строгую границу между свойствами и знаниями провести сложно и иногда говорят, что шарик и вода «знают», что им нужно скатиться вниз.

Главный признак наличия знаний состоит в том, что при создании структуры и заполнении памяти (при ее наличии) объекта были альтернативы. Тогда свойства, проявляемые объектом, определяются не базовыми

физическими законами (круг которых, впрочем, трудно строго очертить), а задаются выбором из некоторых альтернатив при создании и функционировании объекта.

Далее мы будем рассматривать более узкую задачу формирования знаний в памяти в процессе функционирования объекта (системы управления). Знания в системе могут закладываться также и в виде её структуры. М. Тегмарк [3] ввёл в оборот термин «Жизнь 3.0». Она способна не только улучшать знания, хранящиеся в её памяти, но и проектировать свою (или потомков) структуру для улучшения параметров функционирования. Но, даже по Тегмарку, Жизнь 3.0 будет создана человеком, который (пока) не умеет в достаточной степени проектировать свою структуру (хотя отдельные успехи – есть...), а обладает развитыми способностями (в сравнении с другими животными) к формированию новых знаний в своей памяти и на других носителях информации.

Созданные в рамках развития цивилизации технологии автоматической обработки данных позволяют рассматривать возможности формирования знаний в системах управления, работающих без участия человека.

Универсальность

Человечеством накоплены огромные массивы знаний, которые принято классифицировать на фактические и абстрактные, практические и книжные, отличать знания от навыков и много есть других, более тонких разделений типов знаний. Все эти знания в различной мере используются как в ежедневной деятельности людей, так и при создании и работе различных устройств и систем, в которые человеком в разных формах закладываются знания.

При этом человек, в принципе, может освоить любые знания и получать новые знания в любой области деятельности. Более того, нейросетевая революция в машинном обучении заметно продвинула вперёд представления о возможности получения знаний автоматическими системами. Сейчас нейросетевые алгоритмы позволяют освободить разработчиков от изучения свойств входных данных и выявляют необходимые для своей работы знания в процессе обучения.

Нейросетевые алгоритмы уже сейчас обладают достаточно высокой степенью универсальности, поскольку преобразуют сигналы любой природы в активности формальных нейронов и осуществляют обработку входных данных с использованием имеющихся знаний независимо от физического смысла данных.

Тем не менее, существует множество различных структур сетей фор-

мальных нейронов, каждую из которых обычно используют для решения ограниченного круга задач. Это оправдано, поскольку нейросетям ставят относительно простые задачи, с определяемыми человеком целями и оценками. Нейросети выявляют во входных данных необходимые для решения поставленных человеком задач знания и, естественно, для каждого класса задач можно выделять наиболее подходящие для их решения структуры нейросетевых алгоритмов.

Иначе будет обстоять дело, если робот (агент ИИ) при решении своих задач столкнётся с необходимостью получения новых знаний на основе данных, получаемых им из сложной среды. Сложно заранее предсказать, в чём будет состоять проблема, которую предстоит решить. Чем выше универсальность способов получения новых знаний, тем больше вероятность успешного решения задачи.

Аппроксимация

Одним из наиболее универсальных свойств нейросетевых алгоритмов является их способность к аппроксимации преобразований входных данных в выходные. При этом обучение принято рассматривать как улучшение количественных оценок качества аппроксимации «идеального» преобразования (если оно известно, хотя бы в виде примеров). Или просто улучшение оценок преобразования, считая при этом, что оно всё лучше аппроксимирует пусть неизвестное, но «правильное» преобразование.

Правила и онтологии, по сути, состоят из ограниченного списка примеров и правил их применения, в том числе для генерации новых правил. Сгенерировать новые правила, не вошедшие в исходный список (и не основанные на нём), правила и онтологии не позволяют.

Многие полагают, что аппроксимация ничем принципиально не отличается от правил и онтологий: по ограниченному числу запомненных примеров преобразований можно создать потенциально бесконечное число новых примеров преобразований (основанных на известных). Но есть и различие: правила и онтологии создаёт человек, а примеры могут быть запомнены автоматически, без участия человека, на основе наблюдений.

Другими словами, использование аппроксимаций позволяет автоматически (без участия человека) формировать правила и онтологии (пусть в неявном виде), позволяющие производить преобразования входных данных в выходные на основе имеющихся знаний. Но при этом дают возможность получать новые знания, которые не содержались в исходных правилах.

Поскольку нейросети осуществляют аппроксимацию преобразований, то распространено мнение, что достаточно увеличить «глубину» и «мощность» нейросетевых вычислений и любая задача может быть решена. В мае 2022 г. подобное мнение [4] было высказано сотрудниками Гугл.

Но всё не так просто. Выявление новых свойств преобразования при его аппроксимации нейросетевыми алгоритмами теоретически возможно всегда, а на практике есть ограничения, связанные со сложностью преобразования и затратами, необходимыми на построение его аппроксимации.

Сложность

Построение аппроксимаций преобразований построено на использовании статистики наблюдений. А, как известно, всё, что меньше 100, – это не статистика. И, если оптимизируются преобразования входных данных, получаемых от объекта с 3, 5 или даже 10 параметрами, то 10^6 , 10^{10} или 10^{20} примеров ещё как-то можно проанализировать, то для сложных сцен с многими десятками, сотнями и тысячами параметров это невозможно.

Проблема сложности мира состоит как раз в том, что мы не можем планировать свои действия сегодня на основе прямой статистики действий, выполненных в прошлые дни. В одну реку нельзя войти дважды, каждый день проходит не так, как предыдущие.

Но, к счастью, сложный мир состоит из относительно простых объектов и явлений, которые позволяют создавать их модели на основе статистики наблюдений за ними. И уже сейчас нейросетевые алгоритмы используют возможность декомпозиции сложных входных данных на относительно простые компоненты, аппроксимация которых возможна статистическими методами. В противном случае круг решаемых нейросетевыми методами задач был бы значительно уже.

На наш взгляд, для дальнейшего продвижения нейросетевых структур в область всё более сложных «интеллектуальных» задач необходимы:

- явное проведение декомпозиции;
- количественные оценки понимания сложных сцен;
- иерархическая организация декомпозиции сложных сцен;
- использование нескольких режимов выполнения преобразований;
- сознание для управления распределением ресурсов;
- эмоции для управления выбором и соотношением режимов выполнения преобразований.

Сложность реального мира огромна и никакими научными и техническими средствами полностью её преодолеть никогда не удастся. Тем не

менее, вышеперечисленные меры должны, по мнению авторов, позволить передать роботам (агентам ИИ) ряд функций, в настоящее время доступных только человеку. И наибольшее значение имеет возможность познания новых, ранее неизвестных свойств окружающего мира.

Декомпозиция

Действия для сложных объектов и сцен невозможно аппроксимировать, следовательно, необходима декомпозиция на простые составляющие, для которых аппроксимация на основе статистики наблюдений возможно. Но для обработки сложных сигналов необходимо их сравнивать с суммой простых компонент, запомненных ранее.

Для реализации этой идеи необходимо использовать ансамбль нейросетей, осуществляющих не только аппроксимацию преобразований, но и выполняющих автоассоциативную функцию (в современных обозначениях – функцию автоэнкодера).

Для этого преобразования, выполняемые каждой из сетей ансамбля, состоят не только в аппроксимации $\vec{X}_i \rightarrow \vec{Y}_i$, но и $\vec{X}_i \rightarrow \vec{\tilde{X}}_i$, где $\vec{Y}_i$ и $\vec{\tilde{X}}_i$ – запомненные i -й сетью выходной и ассоциативно восстановленный входной векторы, воспроизводимые аппроксимацией по $\vec{X}_i(t)$ – i -й компоненте входного сигнала $\vec{X}$. Выделение $\vec{X}_i$ из сложного сигнала $\vec{X}$:

$$\vec{X}_i(t) = \vec{X}(t) - \sum_{j \neq i}^N \vec{\tilde{X}}_j(t). \quad (1)$$

Аналогичные идеи разделения входного сигнала высказывались ещё в работах [5, 6], но без использования картирования [7] не получили серьёзного развития. В последние годы вопросы компонентного представления сложных входных данных рассматривались, например, в [8].

Следует отметить, что из ансамбля сетей, как правило, бывают активны лишь некоторые, которые сформировали аппроксимации для простых объектов и явлений, которые использовались при формировании сложных входных данных. Для остальных сетей ансамбля вычисляемая по формуле (1) компонента $\vec{X}_i(t)$ близка к нулю и механизмом контрастирования активности они выключаются из работы.

Понимание

Степень близости восстановленного по сумме автоассоциаций $\vec{\tilde{X}}_i$ сигнала к поданным на вход данным

$$\delta(t) = (\vec{X}(t) - \sum_{j=1}^N \vec{\tilde{X}}_j(t))^2 \quad (2)$$

определяет, насколько хорошо соответствуют выделенные компоненты (аппроксимации компонент) поступающим на вход данным. Чем меньше величина $\delta(t)$, тем выше уровень понимания наблюдаемой сцены.

Понимание связано не только с восприятием входных данных, но и с возможностью формирования выходных данных на основе имеющихся знаний, обеспечивающих достижения текущих целей. Эта сторона понимания связана с функцией сознания, которая будет описана ниже.

Получение новых знаний

Разбиение сложных входных данных по формуле (1) и устойчивое понимание правильности осуществлённого разбиения (2) возможны, когда все или большинство компонент сложных данных имеют соответствующие им сети в ансамбле. Если плохо аппроксимируются 1–2 компоненты сложных входных данных, то, хотя на начальном этапе получения новых знаний (про объект или явления, которое не имеет своего представительства в ансамбле сетей), но выделение компонент будет идти в целом правильно. Это позволит процессу обучения (ВРЕ, картирование или другому) обеспечить постепенное улучшение аппроксимации наблюдаемой новой компоненты – получению новых знаний.

Важно отметить, что декомпозиция сложных входных данных на (относительно) простые компоненты не только позволяет использовать имеющиеся знания для ускорения получения новых знаний (а при отсутствии «старых» знаний «новые» может быть не удастся получить совсем), но и объясняет, почему процесс познания в каждой области деятельности обеспечивается в основном именно профильными специалистами, а не произвольными, заинтересованными в проблеме личностями.

Невозможность описания сложного мира ограниченным списком свойств и правил может быть отнесена и к ансамблю нейросетей. Если бы не было возможности его постоянно пополнять новыми знаниями, требовавшихся при попытках достижения различных целей, то постоянно бы возникали неразрешимые проблемы.

Иерархия

Декомпозиция может и должна осуществляться не только на простые объекты и явления, но и на степень общности описаний объектов. Кошка состоит из простых компонент: усы, лапы и хвост, но взаимодействует со средой и другими животными и людьми как целостный объект, проявляющий различные свойства в разных взаимодействиях. Декомпозиция не только на простые объекты, но и на уровни общности параметров позво-

ляет разделить сложные системы на большее число компонент. При этом каждая компонента по отдельности оказывается проще, а значит, построение её описания займёт меньше времени и больше шансов, что менее специализированное описание удастся использовать в других ситуациях.

Но упрощение компонент при иерархическом описании – не главное, что можно таким образом достигнуть. Наличие иерархии позволяет формировать описание и моделировать динамику изменения состояний более общих (и важных для формирования выходных данных) параметров сложных сцен. Если нижние уровни иерархии успешно справляются с изменением параметров текущей ситуации в сторону поставленных целевых значений, то верхние уровни имеют возможность провести сравнительное моделирование изменения состояния сложных сцен при различных действиях (определяемых формируемыми выходными данными) и поставить нижним уровням новые цели не на основе аппроксимации (которая на высоких уровнях иерархии не может быть точной ввиду сложности описываемых объектов), а на основе сравнительного анализа вариантов.

Степень абстрактности

При иерархическом представлении знаний более высокие уровни иерархии соответствуют возрастающей степени абстрактности описания объектов и явлений, а также выполняемых с ними действий. У животных максимальная степень абстрактности представления знаний определяется строением их нервной системы, количеством уровней иерархии нейроструктур. Человек выделился из животного мира в значительной степени благодаря тому, что ему удалось снять данное ограничение. Сначала членораздельная речь, а затем и другие способы коммуникации позволяют передать уже обработанные одним человеком, абстрактные данные на вход НС другого человека с тем, чтобы он выделил в них ещё более абстрактные свойства. В последние годы в обработке данных человеку стали помогать нейросетевые алгоритмы и технологии больших данных.

Синтез и анализ

По существу, работа системы управления по формированию выходных данных имеет три компоненты:

- a) синтез выходных данных на основе входных и поставленной цели;
- b) синтез целей на основе имеющихся данных;

- с) формирование новых знаний на основе анализа входных данных и имеющихся знаний.

Пункт а) выполняется на основе аппроксимации преобразований входных данных и поставленной цели в выходные на нижних уровнях иерархии. Пункт б) тоже выполняется на основе аппроксимации преобразований входных данных, но на более высоких уровнях иерархии, которые рассматривают состояние активности нижних уровней (предобработанное) как входные данные, а сформированные выходные данные передаёт нижним уровням, которые рассматривают их как цели для достижения.

Синтез выходных данных авторы рассматривают как действия на основе интуиции, поскольку выходные данные в данном случае синтезируются без анализа, просто путём аппроксимации ранее выполнявшихся преобразований на основе целей и входных данных. Такой синтез занимает мало времени и может выполняться на любом уровне иерархии.

Но совсем не безразлично, на каком уровне выполняется синтез выходных данных путём аппроксимации. Чем ниже уровень иерархии, тем более точная аппроксимация может быть выполнена. Это связано с тем, что нижние уровни описывают простые объекты и явления в низкоразмерных пространствах состояний. С ростом уровня иерархии увеличивается как сложность объектов, так и число параметров (с учётом параметров нижних уровней, на каждом уровне иерархии число параметров не может быть больше 15–20).

Альтернативой прямому синтезу выходных данных (на различных уровнях иерархии) является анализ различных вариантов действий по достижению глобальных и локальных целей, проводимый не на основе наблюдения внешнего мира (входных данных), а на основе моделирования динамики изменения состояний наблюдаемых объектов и процессов при различных воздействиях и целях. Это, по сути, способ получения знаний не на основе реального опыта взаимодействия с внешним миром, а на основе моделирования взаимодействий простых компонент, про которые имеются накопленные знания. Результаты моделирования не всегда подтверждаются натурными опытами, но в большинстве случаев позволяют улучшить синтез выходных данных, поскольку моделировать можно ситуации, значительно более близкие к сложившейся, чем те, которые встречались в реальности.

Сознание

Цифровое представление данных позволяет осуществить их копирование без потерь, что невозможно себе представить в НС живых организ-

мов. Поэтому у животных синтез и анализ должен происходить на одних и тех же нейроструктурах, поскольку перенос результатов анализа на синтезирующие структуры не имеет сколько-либо реалистичных механизмов.

Но даже если создать цифровую модель, где такой перенос вполне возможен, то всё равно каждый раз возникает вопрос: синтезировать данные на имеющихся знаниях или уточнить эти знания за счёт анализа сложившейся ситуации на основе моделирования?

По мнению авторов, ответ на этот вопрос даёт механизм сознания, который определяет, можно ли повременить с синтезом выходных данных и потратить доступное время на анализ, или на анализ времени нет и необходимо срочно синтезировать данные на основе имеющихся знаний. При этом возможность анализа (мышления) возникает тогда, когда нижним уровням поставлена простая (для конкретного субъекта) цель, которую они могут успешно выполнять в течение некоторого времени без потребности её изменения со стороны верхних уровней.

В рамках предлагаемых представлений сознание – это не отдельный блок НС, а механизм, следящей за распределением ресурсов иерархической структуры на синтез выходных данных и анализ сложившейся ситуации. Чем большее число нижних уровней задействовано на синтез, тем меньшее число верхних уровней может быть использовано для анализа. И соответственно тем менее детализированный анализ ситуации удастся провести.

Эмоции

Выбор сознанием между синтезом и анализом для уровней иерархии – не единственный механизм управления режимами работы нейросетевых структур. Выходные данные можно генерировать для скорейшего достижения поставленных целей, а можно – для опытного получения новых знаний на основе исследовательского поведения. Есть (не жёсткие) альтернативы между защитным и агрессивным поведением, активными действиями и пассивностью, избеганием и взаимодействием с отдельными объектами и явлениями и ряд других режимов функционирования.

Управление этими режимами, по мнению авторов, осуществляется эмоциональной системой, которая управляет не мимикой лица, а соотношением различных режимов работы нейроструктур. Поскольку режимов много, то и управление не сводится к одномерной оценке степени «плохо-хорошо», а является векторной характеристикой, которая может описывать богатый спектр эмоций.

В цифровых нейросетях такое «эмоциональное» управление режимами может быть реализовано путём изменения коэффициентов в формулах активации и обучения у всех формальных нейронов сетевой структуры. У живых организмов эмоциональное управление значениями коэффициентов в механизмах активации и обучения осуществляется путём гормональных воздействий.

Выводы

В короткой статье невозможно изложить все тонкости сложного процесса формирования знаний в иерархических нейросетях. Но некоторые важные аспекты управления работой такой структурой можно соотнести с сознанием и эмоциями, которые, по мнению авторов, не являются отдельными блоками нейросетевой структуры, а механизмами распределения ресурсов на выполнение различных задач и управления режимами работы структуры, на что хочется ещё раз обратить внимание читателей.

Список литературы

1. Ashby W.R. Introduction to Cybernetics. London: Chapman & Hall Ltd. 1956.
2. Bengio Y., LeCun Y., Hinton G. Deep Learning for AI. Communications of the ACM. 2021. V. 64, N 7. P. 58–65.
3. Tegmark M. Life 3.0: Being human in the age of artificial intelligence. New York: Knopf. 2017. 560 p.
4. Reed S., Žolna K., Parisotto E. [et al.]. A Generalist Agent // arXiv preprint arXiv:2205.06175. 2022.
5. Fukushima K. Neocognitron: A Self-organizing Neural Network Model for a Mechanism of Pattern Recognition Unaffected by Shift in Position // Biological Cybernetics. 1980. V. 36, N 4. P. 193–202.
6. Carpenter G., Grossberg S. ART 2: Self-organization of stable category recognition codes for analog input patterns // Applied Optics. 1987. V. 26, N 23. P. 4919–4930.
7. Kohonen T. Self-Organizing Maps. New York: Springer. 2001. 501 p.
8. Sabour S., Frosst N., Hinton G.E. Dynamic routing between capsules // Advances in Neural Information Processing Systems (NIPS). 2017. P. 3859–3869.

АДАПТИВНОЕ ПОВЕДЕНИЕ И ЭВОЛЮЦИОННОЕ МОДЕЛИРОВАНИЕ

**С.А. ПОЛЕВАЯ¹, Л.В. САВЧУК¹, К.Н. ГРОМОВ¹,
А.И. ФЕДОТЧЕВ², С.Б. ПАРИН¹**

¹Национальный исследовательский Нижегородский государственный университет

²Институт биофизики клетки РАН
sofia.polevaia@fsn.unn.ru, fedotchev@mail.ru

ОТОБРАЖЕНИЕ ШКОЛЬНОЙ ДЕЗАДАПТАЦИИ В РЕЖИМАХ ВЕГЕТАТИВНОЙ РЕГУЛЯЦИИ*

В соответствии с принципом экологической валидности для выявления специфики адаптационных процессов, связанных с трудностями обучения, разработана экспериментальная модель, позволяющая воспроизвести базовые компоненты познавательной активности. Экспериментальная модель включает три функциональных контекста: экстремальная когнитивная нагрузка – функциональная проба (ФП) «напряжение» (выполнение корректурной пробы по тесту Тулуз–Пьерона); оптимальная когнитивная нагрузка – ФП «школьная активность» (решение сенсомоторных задач разного уровня сложности), релаксация – ФП «расслабление» (адаптивная нейромодуляция). Выявлено, что у успешных детей проявляется прямая связь между интенсивностью когнитивной нагрузки и напряжением регуляторных систем. У детей с дезадаптацией такая связь отсутствует. Предложенный в исследовании набор сенсомоторных задач разного уровня сложности может быть использован как скрининговый инструмент для дистанционной оценки рисков наличия признаков школьной дезадаптации.

Ключевые слова: *адаптивность, вариабельность ритма сердца, событийно-связанная телеметрия ритма сердца, режимы вегетативной регуляции, когнитивная нагрузка.*

Введение

Начало обучения в школе – исключительно важный этап в развитии ребенка. Анализ литературы показывает, что успешность ребенка в обучении зависит как от личностных характеристик, так и от психофизиоло-

* Данная работа выполнена при частичной поддержке РНФ, грант № 22-18-20075.

гической готовности мозга к обучению [1]. Нарушения в нервно-психической (в первую очередь – когнитивной) сфере у детей и подростков сегодня становятся серьёзной проблемой во всех развитых странах. В рейтинге причин детской инвалидности в Российской Федерации когнитивные расстройства и расстройства поведения занимают 1-е ранговое место. С 2005 по 2016 гг. количество таких детей выросло на 33,5% [2]. По оценкам физиологов около 15% младших школьников проявляют выраженные признаки школьной дезадаптации, выявляющиеся в различных физиологических отклонениях. В связи с острой актуальностью проблемы обучения младших школьников и их адаптации к учебному процессу, необходима разработка новых междисциплинарных подходов как при оценке риска и устранения причин школьной дезадаптации, так и при борьбе с ее последствиями [3]. Целью данного исследования является выявление особенностей вегетативного обеспечения адаптационных процессов при школьной дезадаптации.

Методы

В соответствии с принципом экологической валидности для выявления специфики адаптационных процессов, связанных с трудностями обучения, разработана экспериментальная модель, позволяющая воспроизвести базовые компоненты познавательной активности. Экспериментальная модель включает три функциональных контекста: экстремальная когнитивная нагрузка, оптимальная когнитивная нагрузка, релаксация.

1. В качестве функциональной пробы, провоцирующей экстремальную когнитивную нагрузку (ФП «напряжение»), применена корректурная проба по тесту Тулуз–Пьерона [4].

2. В качестве функциональной пробы, провоцирующей стандартную когнитивную нагрузку, предложены задания на простую и сложную сенсомоторную активность.

3. В качестве функциональной пробы, провоцирующей релаксацию, проводилась процедура адаптивной нейромодуляции на базе резонансного двойного нейробиоуправления: предъявлялся аудиовизуальный контент, созданный на основе собственной ЭЭГ испытуемого [5, 6].

Выборка была разделена на три части: группа «ММД по тесту Тулуз–Пьерона», группа «ниже нормы по тесту Тулуз–Пьерона» и группа «норма по тесту Тулуз–Пьерона». Режим вегетативный регуляции, связанный с каждой функциональной пробой, определялся по спектральным показателям ВРС: TP ($\text{мс}^2/\text{Гц}$) – активность центрального контура управления ритмом сердца и адаптационный потенциал; HF ($\text{мс}^2/\text{Гц}$) – активность

парасимпатической нервной системы; LF ($ms^2/Гц$) – активность симпатической нервной системы; ИВБ – индекс вегетативного баланса, характеризующий напряжение регуляторных систем.

Для выявления особенностей тонууса вегетативной нервной системы при переключении функциональных проб возникла необходимость в стандартизации показателя ИВБ [7]. В качестве способа нормировки, для адекватного цифрового отображения показателя симпатико-вагусного баланса, был применен натуральный логарифм, который позволил осуществить преобразование, при котором одна и та же степень доминирования отображается одним и тем же значением числа, а направление доминирования знаком числа. Это позволило отобразить все возможные варианты динамики тонууса вегетативной нервной системы при переходе от когнитивного расслабления к когнитивному напряжению в прямоугольной системе координат (рис. 1), где

- точки внутри I квадранта соответствуют симпатикотонии на фоне обеих функциональных проб;
- точки внутри II соответствуют ваготонии на фоне пробы «напряжение» и симпатикотонии на фоне пробы «расслабление»;
- точки внутри III квадранта соответствуют ваготонии на фоне обеих проб;
- точки внутри IV квадранта соответствуют симпатикотонии на фоне пробы «напряжение» и ваготонии вегетативному тонуусу на фоне пробы «расслабление».




Рис. 1. Цифровое отображение динамики вегетативного обеспечения когнитивной нагрузки

Результаты

Для определения особенностей вегетативного обеспечения адаптационных процессов при школьной дезадаптации проведен сравнительный анализ показателей variability ритма сердца в трех группах [7]. Основанием для распределения по группам служили значения показателей скорости (V) и точности (K) по тесту Тулуз–Пьерона, попадающие нормативно:

- в зону ниже нормы, но не в зону патологии,
- в зону патологии с минимальной мозговой дисфункцией (ММД),
- в возрастную норму или выше нормы.

Выявлено, что не все испытуемые, имеющие предварительный диагноз на основании клинической оценки, попали в группу «ММД» или «ниже нормы» по тесту Тулуз–Пьерона, в то время как вся группа контроля попала в «норму» (рис. 2). Связь между классификацией по уровню умственной деятельности по тесту Тулуз–Пьерона и клинической классификацией не выявлена.




Рис. 2. Связь между уровнем умственной деятельности по тесту Тулуз–Пьерона с клиническим диагнозом детей со школьной дезадаптацией. ТР – доля детей с диагнозом «тревожные расстройства», СДВГ – доля детей с диагнозом «синдром дефицита внимания с гиперактивностью», ОЗГМ – доля детей с диагнозом «органические заболевания головного мозга», Контроль – доля здоровых (без клинического диагноза)

Выявлены особенности тонуса вегетативной нервной системы при переключении крайних функциональных проб, с учетом распределения испытуемых в соответствии с результатами по тесту Тулуз–Пьерона (рис. 3).

Группе «норма по тесту Тулуз–Пьерона» соответствует 4 тип динамики ИВБ, когда симпатотония обеспечивает выполнение функциональной пробы «напряжение», а ваготония характерна для функциональной пробы «расслабление».

В группе «ниже нормы по тесту Тулуз–Пьерона», при переключении крайних функциональных проб, наблюдается ваготония как на фоне пробы «напряжение», так и на фоне пробы «расслабление». У детей этой группы не сформирована функциональная система, обеспечивающая усиление энергообеспечение при увеличении требований к интенсивности когнитивных процессов.

Группе «ММД» соответствует вариант динамики тонуса вегетативного баланса по 1 типу, когда симпатикотония наблюдается на фоне обеих функциональных проб. У детей этой группы не сформирована функциональная система, обеспечивающая расслабление при отсутствии когнитивной нагрузки.

Таким образом, есть основания предполагать, что проблемы в обучении у детей могут быть связаны с отсутствием адаптивности в режимах вегетативного обеспечения когнитивных процессов.




Рис. 3. Динамика вегетативного обеспечения когнитивной нагрузки при переключении функциональных проб «напряжение»/«расслабление» в группах детей с разным уровнем умственной деятельности по тесту Тулуз–Пьерона

Когортный анализ динамики вегетативной регуляции по спектральным показателям variability ритма сердца при переключении трех функциональных проб «напряжение», «школьная активность» и «расслабление» позволил выявить сходство и различие вегетативного обеспечения когнитивных процессов в группах «ММД по тесту Тулуз–Пьерона», «ниже нормы по тесту Тулуз–Пьерона» и «норма по тесту Тулуз–Пьерона».

В группе «норма по тесту Тулуз–Пьерона» значение всех показателей в трех функциональных пробах достоверно отличаются друг от друга, что свидетельствует о разном ответе регуляторных систем на уровень нагрузки при переключении функциональных проб. В контексте пробы «напряжение» наблюдается минимальное значение показателя общей мощности спектра вариабельности ритма сердца и повышение уровня напряжения регуляторных систем с доминированием симпатического звена ВНС. В контексте пробы «школьная активность», где отдых чередуется с выполнением заданий разного уровня сложности, закономерно наблюдается средний уровень напряжения регуляторных систем, рост значений спектральных показателей в диапазонах LF и HF и максимальное значение общей мощности спектра вариабельности ритма сердца. В контексте пробы «расслабление» происходит существенное снижение уровня напряжения, доминирует парасимпатическое звено ВНС, а значение общей мощности спектра вариабельности ритма сердца находится на среднем уровне (рис. 4А). Таким образом, у успешных детей максимальный адаптационный потенциал связан со средним уровнем когнитивной нагрузки.

В группе «ММД по тесту Тулуз–Пьерона» значения всех показателей в трех функциональных пробах также достоверно отличаются друг от друга. На фоне пробы «напряжение» наблюдается максимальное снижение общей мощности спектра вариабельности ритма сердца, редукция центрального контура регуляции и повышение уровня напряжения регуляторных систем с доминированием симпатического звена ВНС. По мере снижения нагрузки в ФП «школьная активность» и «расслабление» происходит рост общей мощности спектра вариабельности ритма сердца и снижение уровня напряжения, однако даже в положении лежа (ФП «расслабление») доминирует симпатическое звено ВНС, а уровень напряжения регуляторных систем остается высоким (рис. 4Б).

В группе «ниже нормы по тесту Тулуз–Пьерона» значения всех показателей, кроме LF, при переключении трех функциональных проб, достоверно отличаются друг от друга. Ваготония наблюдается на фоне всех функциональных проб, по мере снижения нагрузки в функциональных пробах происходит рост общей мощности спектра вариабельности ритма сердца, максимальный уровень напряжения наблюдается в ФП «школьная активность», что может быть связано с трудностями переключения между задачами (рис. 4В).

Таким образом, при снижении умственной деятельности в группах «ниже нормы» и «ММД» максимальный уровень адаптационного потенциала проявляется в функциональной пробе «расслабление» при отсут-

ствии когнитивных нагрузок.




Рис. 4. Стандартизованные значения спектральных показателей variability ритма сердца в группах «Норма» (А), «ММД» (Б), «ниже нормы» (В), звездочками отмечены достоверные различия

Заключение

Разработанная экспериментальная модель, воспроизводящая базовые компоненты познавательной активности, проявила особенности вегетативного ответа на разные типы нагрузки у детей с признаками школьной дезадаптации. Характер вегетативного ответа на изменение уровня нагрузки не связан напрямую с клиническим статусом, а находится в соответствии с уровнем внимания и активности. На фоне всех функциональных проб в группах, имеющих слабый и патологически низкий уровень активности и внимания, наблюдаются противоположные состояния психофизиологической системы, в первом случае результатом является недостаточная активация, во втором случае – избыточное напряжение. Предложенный в исследовании набор сенсомоторных задач разного уровня сложности может быть использован как скрининговый инструмент для дистанционной оценки рисков наличия признаков школьной дезадаптации.

Список литературы

1. Ефимова В.Л. Психофизиологический подход к анализу механизмов возникновения трудностей в обучении у детей (обзор зарубежных источников) // Психология образования в поликультурном пространстве. 2020. № 2(50). С. 28–39.
2. Мальцев С.В., Сафина Л.З., Биктимирова А.А., Мансурова Г.Ш. Состояние здоровья школьников – медицинские и социальные проблемы // Практическая медицина. 2019. № 17(5). С. 8–15.
3. Баландина О.В., Божкова Е.Д., Дворянинова В.В., Катунова В.В., Коновалов А.А. Коррекция школьной дезадаптации на основе междисциплинарного подхода // Медицинский альманах. 2019. № 2(59). С. 24–29.
4. Ясюкова Л.А. Прогноз и профилактика проблем обучения в начальной школе. Санкт-Петербург : ИМАТОН, 2006. 204 с.
5. Frederick J.A. Psychophysics of EEG alpha state discrimination // Conscious Cogn. 2012. No. 21(3). P. 1345–1354.
6. Федотчев А.И., Земляная А.А., Полевая С.А., Савчук Л.В. Синдром дефицита внимания с гиперактивностью и современные возможности его лечения методом нейробиоуправления // Журнал неврологии и психиатрии им. С.С. Корсакова. 2016. № 116(5). С. 98–101.
7. Полевая С.А., Еремин Е.В., Буланов Н.А., Бахчина А.В., Ковальчук А.В., Парин С.Б. Событийно-связанная телеметрия ритма сердца для персонализированного дистанционного мониторинга когнитивных функций и стресса в условиях естественной деятельности // Современные технологии в медицине 2019. № 11(1). С. 109–115.

SAMER EL-KHATIB¹, Yu.A. SKOBTSOV², S.I. RODZIN¹

¹Southern Federal University, Russia

²St. Petersburg State University of Aerospace Instrumentation, Russia

samer_elkhatib@mail.ru, srodzin@yandex.ru, ya_skobtsov@list.ru

OPTIMAL NUMBER OF ANTS DETERMINATION IN IMAGE SEGMENTATION METHOD FOR COMPLEXLY STRUCTURED IMAGES*

For image segmentation ant colony optimization algorithm is proposed. The number of ants affects the computational complexity of this method. It is a mistake to believe that the more ants, the better. With a large number of ants in a colony, productivity drops significantly, since the operating time of the method greatly increases, an overabundance of pheromones occurs, and the method gets stuck at the local optimum. The Hybrid Ant Colony Optimization (ACO) – k-means and optimal number of ants detection for complexly structured images are considered in this paper.

Keywords: *images segmentation, complexly structured images, ant colony optimization, k-means algorithm.*

Introduction

The demanded areas of digital image recognition are medicine, space, industry, art and many others [1]. Complexly structured images are one of the most complex and significant objects. Complexly structured images are understood as images with a non-deterministic and non-linear structure, which consist of a large number of composite elements with significant characteristics. Complexly structured images are semantically rich images. Complexly structured images have the following properties:

- The presence of a large number of dissimilar objects in the image;
- Objects in the image are of different types;
- Each type of object has its own significant characteristics that must be taken into account;
- Objects are morphologically complex structures;

* The reported study was funded by Russian Foundation for Basic Research according to the research project № 19-07-00570 “Bio-inspired models of problem-oriented systems and methods of their application for clustering, classification, and filtering and optimization problems, including big data”.

The research described in this paper is partially supported by the Russian Foundation for Basic Research grant № 20-08-01046, state research FFZF-2022–0004.

- The color distribution of the object and the background most often does not intersect.

Examples of such images can be geographical and topographic maps, images of the Earth's surface from space, etc. The most obvious example of complex structured images are medical images, in particular, images obtained using magnetic resonance imaging (MRI images).

Segmentation is the process of dividing the initial complexly structured image of size $M \times N$ into K clusters so that they differ as much as possible from each other and represent the objects of the original image. Given the initial images in the form of a set of pixels with visual properties such as brightness, color, texture, as well as a certain size, noise level, contrast and quality, it is necessary, within the available resources to find such a marking of digital images for a certain number of K clusters, which provides high accuracy and subsequent recognition quality.

A cluster means a certain isolated area, consisting of separate elements (pixels), such that the distance between its elements is minimal, and the distance between two adjacent areas is maximal.

Ant methods have shown their competitiveness in solving many NP-complete transcomputational problems [2] and are of interest for use in the problem of image segmentation [3, 4].

The input data for the method are the following parameters:

- K is the number of clusters into which the original image must be split;
- m is the number of ants that directly perform segmentation;
- η_0 is the maximum number of iterations of the method for finding a solution;
- α is parameter that controls the degree of influence of the pheromone level;
- β is a heuristic parameter that controls the degree of belonging of a pixel to a certain cluster.

In this article we will investigate parameter m that is the number of ants of proposed algorithm.

Hybrid Ant colony optimization k-means method for image segmentation

A distinctive feature of the proposed bio-inspired ant method of image segmentation is the use of fast cluster analysis (k-means) [6] to recalculate the center of each segment and the use of a superposition of several criteria for the optimality of the solutions obtained, taking into account both color and geomet-

ric characteristics of the image [7–11]. The image can be either color or gray-scale, with different initial conditions (noise, high contrast, good quality, blur).

At the first stage of the method, it is necessary to set the value of the number of clusters and initialize their centers. Further, the belonging of each pixel of the image to a certain cluster is determined, according to the probability, which is inversely proportional to the distance between the pixel, the center of the cluster and the variable τ , which represents the pheromone level:

$$P_i(X_n) = \frac{[\tau_i(X_n)]^\alpha [\eta_i(X_n)]^\beta}{\sum_{j=0}^K [\tau_j(X_n)]^\alpha [\eta_j(X_n)]^\beta}, \quad (1)$$

where $\tau_i(X_n)$ and $\eta_i(X_n)$ is information about pheromone and heuristic variable values of belonging of a pixel to the cluster i respectively, α and β are heuristic coefficients of ACO algorithm, k is a number of clusters. Heuristic information is obtained as follows:

$$\eta_i(X_n) = \frac{k}{CDist(X_n, CC_i) * PDist(X_n, PC_i)}. \quad (2)$$

where X_n is n^{th} pixel, CC_i is i^{th} spectral cluster center, PC_i is i^{th} spatial cluster centre, $CDist(X_n, CC_i)$ is the distance between (X_n, CC_i) according to colour characteristics – (3), $PDist(X_n, PC_i)$ is the geometrical distance between (X_n, PC_i) – (4), k is constant value.

$$CDist(X_n, CC_i) = |Int(X_n) - Int(CC_i)|, \quad (3)$$

where $Int(X_n)$ is the intensity of the pixel X_n .

$$PDist(X_n, PC_i) = \sqrt{(X_n.x - PC_i.x)^2 + (X_n.y - PC_i.y)^2}, \quad (4)$$

where $X_n.x$ and $X_n.y$ are x and y coordinates respectively for the pixel X_n .

The target function (fitness function) is important for the bio-inspired ant method. In the bio-inspired ant method proposed in the article for solving the problem of segmentation of complex-structured images, the following set of rules is used as a criterion for finding an optimal solution:

$\max (\sum_{k=1..K-1} \sum_{j=k+1..K} CDist(C_k, C_j))$ is the maximum sum value of the

color distance between the cluster centers for all ants (the distance between the clusters, in terms of color characteristics, should be at a maximum, then clusters will be different from each other), where $CDist$ – the color distance between two pixels, C_k is center of the cluster k .

$\min (\sum_{k=1..K} \sum_{p=1..S_k} PDist(C_k, X_p))$ is the minimum value of the sums of

geometric distances between the centers of the clusters and the pixels belonging to the cluster (the sum of the Euclidean distances between the center of the cluster and each of its pixels should be minimal, , according to the spatial characteristics, respectively, the cluster will be more homogeneous), where S_k is the number of pixels in the cluster k , $PDist$ – Euclidian distance between two pixels, C_k is center of the cluster k .

$\min (\sum_{k=1..K} \sum_{p=1..S_k} CDist(C_k, X_p))$ is the minimum sum value of the color

distances between the centers of the clusters and the pixels belonging to the cluster (sum of the Euclidean distances between the center of the cluster and its each pixel, according to color characteristics, should be minimal, then, the cluster will be more compact), where S_k is the number of pixels in the cluster k , $CDist$ – the color distance between two pixels, C_k is center of the cluster k .

The fitness function of the ant colony is 3-criterial and can be obtained as follows:

$$f(m_i) = \begin{cases} f_1 = \sum_{k=1..K-1} \sum_{j=k+1..K} CDist(C_{m_i k}, C_{m_i j}), \\ f_2 = \sum_{k=1..K} \sum_{p=1..S_{m_i k}} PDist(C_{m_i k}, X_{m_i p}), \\ f_3 = \sum_{k=1..K} \sum_{p=1..S_{m_i k}} CDist(C_{m_i k}, X_{m_i p}). \end{cases} \quad (5)$$

Choice of the best solution can be presented as:

$$f(best) = \sum_{i=1..m} \begin{cases} \max(f_1) \\ \min(f_2) \\ \min(f_3) \end{cases} \quad (6)$$

Pheromone updating is calculated as in standard ACO algorithm according to:

$$\tau_i(X_n) \leftarrow (1 - \rho)\tau_i(X_n) + \sum_i \Delta\tau_i(X_n) \quad (7)$$

and pheromone evaporation is calculated as:

$$\Delta\tau_i(X_n) = \begin{cases} \frac{Q * Min(k')}{AvgCDist(k', i) * AvgPDist(k', i)}, & \text{if } X_n \subset \text{cluster } i \\ 0, & \text{otherwise} \end{cases}, \quad (8)$$

where Q is a constant value, $Min(k')$ is the minimum color outer cluster distance found by the most successful ant, $AvgCDist(k', i)$ and $AvgPDist(k', i)$ is the average value of the spatial Euclidean and color distances between each pixel and cluster centers for the most successful ant.

Hybrid ACO algorithm for image segmentation consists of the following steps:

Algorithm 1. Hybrid ACO-k-means segmentation algorithm

```

Begin
  Initialize([number clusters], [number ants]);
  Repeat
    For each ant do
      M: For each pixel do
        Calc(probability belonging pixel to cluster) (1);
      End
      Update (cluster center);
      If (NewCenter > OldCenter) then
        goto M;
      Else
        Save(current solution);
      End
    Select Best Solution From All Ants (5);
    Update(for each pixel) (6, 7);
    Correct(common solution);
  Until criteria not reached
End

```

Determination of the optimal settings for the hybrid ant method

The effectiveness of the ant method depends on a number of initial parameters discussed below. In this article we will investigate m , where m is the number of ants. The number of ants affects the computational complexity of the method. It is a mistake to believe that the more ants, the better. With a large number of ants in a colony, productivity drops significantly, since the operating time of the method greatly increases, an overabundance of pheromones occurs, and the method gets stuck at the local optimum.

To analyze and calculate changes in the main heuristic parameters of the proposed method, complexly structured images from the Ossirix set [5] were used. The original images were divided into several groups. Let us describe here the general research methodology for determining the optimal parameters of the hybrid ant method. As an example, a complex snapshot from the BRAIN collection of the Ossirix set called IM-0001-0002.dcm is used. This complexly structured image has the following parameters: width – 109; height – 106; good quality; format – 8 bits per pixel; size – 38 Kb; the group is the brain. The clustering parameters are the number of clusters $K = 5$; the maximum number of method iterations. To identify the optimal values of the parameters of the hybrid ant method of segmentation, the images were studied under various initial conditions (noise, contrast, blur). The influence of the values of the initial cluster centers on the behavior of the method and the final result was also investigated.

So, with automatic segmentation, we investigated the effect of changing such a parameter of the method as the number of ants on the value of the objective function of the best ants (2.3). The values are presented in the format of formula (5), where the first value matches and the last one. As this table large enough we will not publish it in this article.

The same experiments as for described image we provided for all the rest complexly structured images from Ossirix dataset. The results were processed and presented as diagram 1.




Fig. 1. The range of values for the optimal number of ants is depending on the size of the image

The data in Fig.1 are summarized results for automatic segmentation by the hybrid ant method.

So, presented diagram shows optimal range of ants in dependency of image sizes. Figure 1 shows that with an image size of up to 50×50 pixels, it is rational to use no more than 5 ant agents. At large values of the image size (up to 800-800 pixels), it is advisable to limit the number of ants to no more than 60. These values were obtained experimentally, however, due to the stochastic nature of the method and various variants of combinations of initial arrangements of ants, optimal or close to optimal solutions were achieved with both a smaller and a larger number of ants, but much less frequently.

Conclusion

In the article was presented Hybrid ACO-k-means method for complexly structured images segmentation. Optimal number of ants investigation was performed that showed that it is rationally to use not more than 60 ants for images greater than 800x800 pixels.

References

1. Gonzalez R.C., Woods R.E. Digital Image Processing. 3rd edition. Prentice-Hall. 2008.
2. Kennedy J., Eberhart R.C. Particle swarm intelligence // Proceedings of the IEEE International Joint Conference on Neural Networks. 1995. P. 1942–1948.
3. Bozhenyuk A., El-Khatib S., Kacprzyk J., Knyazeva M., Rodzin S. Hybrid Ant Fuzzy Algorithm for MRI Images Segmentation // Rutkowski L., Scherer R., Korytkowski M., Pedrycz W., Tadeusiewicz R., Zurada J. (eds) Artificial Intelli-

- gence and Soft Computing. ICAISC 2019. Lecture Notes in Computer Science. Springer, Cham. V. 11509.
4. Saatchi S., Hung C.C. Swarm intelligence and image segmentation swarm intelligence. ARS J. 2007
 5. Ossirix image dataset. <http://www.osirix-viewer.com/>
 6. Hartigan J.A., Wond M.A. Algorithm AS 136: A K-Means Clustering Algorithm // Journal of the Royal Statistical Society. Series C. 1979. V. 28, N 1. P. 100–108.
 7. Skobtsov Y.A., Speransky D.V. Evolutionary computation: hand book. Moscow: The National Open University "INTUIT". 2015. 331 p. (in Russian).
 8. El-Khatib S., Skobtsov Y., Rodzin S. Improved Particle Swarm Medical Image Segmentation Algorithm for Decision Making // Kotenko I., Badica C., Desnitsky V., El Baz D., Ivanovic M. (eds) Intelligent Distributed Computing XIII. IDC 2019. Studies in Computational Intelligence. Springer, Cham. 2020. V. 868. P. 437–442.
 9. El-Khatib, S.A., Skobtsov, Y.A. and Rodzin, S.I. Theoretical and Experimental Evaluation of Hybrid ACO-k-means Image Segmentation Algorithm for MRI Images Using Drift-analysis // Procedia Computer Science. 2019. V. 150. P. 324-332.
 10. El-Khatib S., Skobtsov Y., Rodzin S., Zakharov V. (2021) Comparison of Modified Object Detected Graph Cut and Hybrid Ant Colony Optimization – k -means for MRI Images Segmentation // Silhavy R. (eds) Software Engineering and Algorithms. CSOC 2021. Lecture Notes in Networks and Systems. Springer, Cham. V. 230.
 11. El-Khatib S., Skobtsov Y., Rodzin S., Potryasaev S. (2020) Comparison of Hybrid ACO- k -Means Algorithm and Graph Cut for MRI Images Segmentation // Silhavy R. (eds) Artificial Intelligence and Bioinspired Computational Methods. CSOC 2020. Advances in Intelligent Systems and Computing. Springer, Cham. V. 1225.

И.В. ТИХОНОВ¹, А.А. ЖДАНОВ²

¹Московский физико-технический институт (национальный исследовательский университет)

²Институт точной механики и вычислительной техники им. С.А. Лебедева РАН, Москва

tikhonov.iv@phystech.edu ¹, alexander.a.zhdanov@gmail.com ²

**АДАПТИВНЫЙ АЛГОРИТМ ТРЕКИНГА ЗАДАЧ
РЕАЛЬНОГО ВРЕМЕНИ**

В статье разобрано построение адаптивного алгоритма трекинга. Решение предполагает накопление и обновление знаний о многомерном движении объектов в процессе управления их распознаванием в режиме реального времени. Накопление знаний учитывает оценку качества распознавания, которая используется в процессе управления. Алгоритм формирует новые многоуровневые образы из множества уже распознанных. Произведено моделирование на основе реального видеопотока.

Ключевые слова: *трекинг, автономное адаптивное управление, отслеживание объекта, прогнозирование, машинное зрение, нейронные сети.*

Введение

Задача трекинга – отслеживание объектов в видеопотоке, является классической задачей компьютерного зрения. Применение трекинга в таких задачах, как распознавание номера машины, построение автопилота, отслеживание брака на производственной линии или охранные мероприятия, не ново. Нередко возникает потребность в сохранении информации о том, что отслеживаемый объект с разных кадров является одним и тем же. Например, отслеживание конкретного товара или продукта на этапах конвейерной обработки или, например, аудит количества деревьев в лесозаготовке на всех этапах следования лесовоза (рис. 1). Еще один пример – аналитика спортивных игр, где надо отслеживать каждого уникального игрока (рис. 2) во время матча.

Распознаваемые объекты могут меняться как в пространстве, так и во времени. Устоявшимся конвейером в построение систем трекинга является накопление достаточной обучающей выборки для каждого распознаваемого класса и дальнейшее обучение нейросети. Для объектов, которые меняются или выделяются в подклассы, такие алгоритмы требуют или дообучения или полного переобучения. Эти недостатки были исправлены нами в текущем решении.

В работе рассматриваются два прикладных сценария построения алгоритма. Первый предполагает базовые ограничения на точность: система распознавания (СР) должна обладать некоторым минимум знаний, относительно распознаваемых объектов, т.е. СР должна быть предварительно обучена на небольшой обучающей выборке и в процессе функционирования повышать качество распознавания по мере накопления знаний об объекте и его траектории. Например, такое ограничение накладывается при автоматизации лесозаготовки при распознавании срезов бревен, подвозимых к месту разгрузки (рис. 1).



Рис. 1. Анализ количества и диаметров бревен на разных этапах лесозаготовки

Второй сценарий предполагает, что практическая задача не накладывает ограничений по точности и алгоритм может автоматически выделять образы без заранее заложенных, предобученных классов прямо в процессе распознавания. Например, в задаче аналитики спортивных игр, разнообразие спортсменов по форме, росту, положению и траекториям движения накладывает большие требования на объем обучающей выборки при обычном обучении нейросетей. Если же позволить алгоритму управлять процессом распознавания самостоятельно, то выделение первых траекторий происходит уже с первых секунд записи (рис. 2). Важно отметить, что наш алгоритм не был предварительно обучен локализовывать, отслеживать и распознавать людей или спортсменов. Таким образом, спустя несколько секунд (моменты времени 1 и 2) траектория игрока в левой нижней части кадра уже начала отслеживаться. Такой подход связан с большим количеством шума в первые десятки минут работы программы, по-

скольку накапливаемых данных недостаточно, и программа захватывает объекты движущегося фона. Однако по мере увеличения количества примеров качество работы возрастает, что устраняет длительный и, что самое важное, дорогостоящий этап накопления и разметки обучающей выборки при устоявшихся в отрасли процедурах обучения.




Рис. 2. Аналитика спортивных игр, 4 кадра с интервалом 5 секунд

На текущий момент не существует надежных нейросетевых решений, способных к переобучению по мере изменения объектов или конкретной среды. В текущей работе мы развиваем подход к решению проблем трекинга, представленный нами ранее в работах [1, 2].

В работе [1] нами была предложена система отслеживания распознаваемых объектов реального времени (*трекинга*). Под режимом реального времени будем подразумевать процесс трекинга с частотой более 30 кадров в секунду. Предложенная система формирования и распознавания образов (ФРО) была устроена так, что процесс управления заключался непосредственно в управлении процессом распознавания на основе прогнозируемых траекторий. Прогнозы были основаны на результатах распознавания предыдущих кадров (*Tracking-nn*). Такой подход был выработан на основе представлений о работе биологических систем распознавания. Алгоритму требовалось проверять куда меньше гипотез о положениях различных объектов, поскольку зачастую изменение положения объекта между соседними кадрами были незначительными и, соответственно, легко прогнозируемыми. Это изменение позволяло повысить быстродействие алгоритма.

В работе [2] разработка алгоритма велась исходя из представлений о методологии автономного адаптивного управления (ААУ) [3]. Одним из требований на автономность алгоритма, согласно ААУ, является то, что управляющая система (УС) является подсистемой объекта управления (ОУ) и принимает управляющие решения самостоятельно, не получая непосредственных указаний извне. Мы использовали СР как объект управления для системы ААУ. Описанный нами в [1] алгоритм генерировал гипотезы относительно будущего положения распознаваемого объекта, наводя СР на эти области. Алгоритм обладал недостатками, связанными с тем, что УС требовала предварительного обучения на интересующих траекториях. В работе [2] нами было предложено решение, которое позволяло УС не привязываться к определенным заранее образам. Тем самым, УС адаптировалась, автоматически формируя знания о типичных траекториях движения наблюдаемого объекта и накапливая их в базе знаний (БЗ).

Помимо автоматического формирования знаний о траекториях, в [2] система ААУ (см. п.1) формировала новые образы. Так, например, класс “автомобиль”, заранее распознаваемый в СР, мог быть разбит на подклассы “легковой”, “грузовик” в процессе реализации алгоритма. Сформированные подклассы идентифицировались номерами. В настоящей статье демонстрируется самообучаемая СР.

Еще одним из критериев адаптивности, согласно ААУ (см. п.4), является автоматическое накопление новых знаний, сохраняемых в БЗ. Под знанием здесь понимается тройка объектов: образ текущего состояния, действие и образ результата, формализованных ниже. Предшествующее решение [2] имело ряд ограничений, связанных с трекингом длинных траекторий. Помимо этого, проблема заключалась в отсутствие критерия качественных оценок, из-за чего отличить качество выбора близких и разнонаправленных направлений в процессе управления направлением распознавания представлялось невозможным. Здесь мы вводим такой критерий.

Задачей работы являлась реализация описанных выше критериев, которые мы развивали в работе [2]. Полученный нами алгоритм позволяет строить полноценные адаптивные системы трекинга. В работе сохранено и улучшено автоматическое извлечение знаний, благодаря чему сохраняется возможность обнаруживать объект в течение движения по изображению. Полученную улучшенную УС и ФРО можно сравнивать по скорости и точности задачи детекции с актуальными алгоритмами, такими как YOLOv4 [4], DINO [5], SWIN [6], однако такие свойства, как удержание

объекта, их подсчет, формирования новых образов из существующих или без заранее заложенных и в них, отсутствуют.

Предлагаемый алгоритм трекинга

Для начала рассмотрим процесс формирования образов, затем операции с образами и вывод знаний.

В работе [2] распознавание изображения происходило с помощью дообучаемой нейросети, устройство которой предполагало выделение сжатого векторного представления образа (*эмбединга*). Полученный эмбединг в дальнейшем может быть отнесен к заранее обученному классу с помощью финального классификационного слоя. По мере работы алгоритма для каждого кластера накапливается необходимое число примеров, которые в дальнейшем кластеризуются, позволяя уточнять классы.

Реализованный процесс формирования образа СР приведен на рис. 3. Приведенная архитектура используется как в подходе с предварительно заложенными дообученными классами, как это было в работе [2], так и с их отсутствием и формированием образов в результате самообучения. В качестве распознающей изображение нейросети используется архитектура YOLOv4 [4], выделяющая разнообразные признаки на разных картах активации, по сути, позволяя распознавать объекты разных масштабов. Иными словами, полученные представления (карты активаций) содержат пространственный эмбединг определенного участка изображения в разных масштабах. На рис. 3 это выделено в качестве закрашенного ромба в третьем блоке карт активаций, где приблизительно располагается баскетболист. Выделяя эмбединги разных участков для близких по времени кадров (рассматривались 0.5 и 1 секунда), можно находить те области, где эмбединг изменялся сильнее всего. Такая область схематически закрашена в правой нижней части рис. 3.

Имея эмбединг участка, в примере это баскетболист, модель может сохранить его для дальнейшего сопоставления со следующими кадрами и удержания объекта. Используя подход, предложенный нами в работе [2], мы также можем управлять последующими шагами распознавания, что уберет потребность в сопоставлении всех эмбедингов участков изображения с разных временных шагов. Более того, полученный эмбединг представляет собой не общий эмбединг изображения, а конкретную зону отслеживаемого объекта.




Рис. 3. Архитектура решения

Как было описано выше, предполагается два варианта работы. Первый предполагает изначальные требования на точность, как в предшествующей работе, использование заранее обученных или дообученной на небольшой выборке сверточных нейросетей. В ходе работы алгоритма эмбединги образов накапливаются и кластеризуются во время функционирования алгоритма, что позволяет создавать подклассы. Отличия от работы [2] состоят в том, что такие эмбединги теперь не векторное представление изображения, на котором могут находиться несколько образов, а двумерные карты активаций нужной части изображения, проецируемые с разных масштабов.

Второй вариант не предполагает наличия заранее обученных классов, полученных в результате предварительного обучения или дообучения. Такой способ помечает классы порядковым номером, однако описание пространственного эмбединга на языке признаков (зоны изображения, в которой происходит изменения), иными словами, численное представление, будет схожим при перемещении по изображению в рамках одинаковых масштабов, что сильно экономит на времени и бюджете при разметке.

Согласно методологии ААУ, “знание” состоит из трех образующих – образа условия, возможного действия и закономерного результата, упорядоченная совокупность которых формирует БЗ. Устройство БЗ в текущей работе схоже с тем, что рассматривалось нами в работе [2]. В качестве образа действий рассматривается управление трекингом, т.е. выбор одно-

го из 16-ти направлений, одно из которых в каждый момент времени t может выбрать подсистема принятия решений. Ключевым отличием является то, что мы сохраняем в БЗ не только текущее выбранное направление, а еще d штук (было выбрано 2) дополнительных, предшествующих ему направлений dt (было выбрано 0.5 с.) шагов назад. Таким образом, мы следим не за траекторией движения вдоль смежных кадров, которые обычно мало отличаются, а за динамикой движения последних секунд. Такой образ формируется для каждого момента времени t , $O_i(t)$, где $i = 1, 2, \dots, N$. Множество $\Omega_1 = \{O_i(t)\}$ является алфавитом классов или множеством “образов условия”. Количество уникальных образов N не ограничено из-за возможности системы ФРО предлагаемого алгоритма формировать новые образы в течение всей работы. Оно может быть как нулевым, если алгоритм не предобучен, так и равным $N = 80$, что является типичным количеством предобученных образов в задаче детекции.

Пусть результаты совершения действия представлены подмножеством из множества $\Omega_2 = \{O_z(t)\}$, где $z = 1, 2, \dots, L$, что является “образом результатов”. На рис. 4 показан пример со спортивными соревнованиями, в котором спустя две секунды все спортсмены начинают отслеживаться. Так, объект “спортсмен” движется по беговой дорожке – последовательность комбинаций из нескольких направлений, образующих элемент дуги. БЗ является таблица из 48 (16×3) строк (возможных направлений за 3 шага) и N образов. Подсистема формирования базы знаний будет наблюдать за процессом управления и следить за повторением троек (i, j, z) , соответствующих событиям $(O_i(t-2), D_j(t-1), O_z(t))$. Если событие произошло не менее M раз (будем полагать $M = 2$), то в клетку БЗ (i, j) записывается число прецедентов сонаправленности. Иными словами, это происходит после двух прецедентов распознавания определенных образов на соседних временных шагах при определенном совершенном действии.

При накоплении в БЗ достаточного числа прецедентов система формирует новый образ. При управлении УС распознает те образы, которые уже сформированы, и совершает действие, которое обещает, согласно БЗ, перевести систему в состояние с максимально возможной качественной оценкой. Критерием такой оценки мы считаем усредненную косинусную близость, что позволяет оперировать в ситуациях, когда БЗ еще не заполнена до конца, но существуют близкие направления.

Практические примеры

На рис. 1 приведен пример обработки изображений видеопотока на лесозаготовительном производстве на этапе подъезда лесовозов к месту раз-

грузки. Система контролирует количество бревен на всех этапах следования лесовоза, что позволяет проводить аудит по объемам и сокращать издержки [7].

На рис. 2 и 4 показаны примеры применения нашего алгоритма в задачах анализа спортивных игр. Такие системы уже востребованы на рынке, например [8].




Рис. 4. Спортивные соревнования

Постановка эксперимента

Результаты модельного эксперимента представлены на рис. 1, 2, 4. Для примера соревнований (рисунок 4) рассмотрена визуализация БЗ (рис. 5) из 30 секунд видео. Поскольку вся видеозапись идет только вдоль беговой дорожки, выделенные образы соответствуют только набору движений в правый нижний угол (номера 15, 30, 45).

В текущей работе были развиты идеи, предложенные в статье [2]. Выше была продемонстрирована возможность заполнения БЗ и дальнейшее отслеживание объектов даже за небольшое число кадров, что не требует тысяч итераций, как в программе, описанной в [2]. Реализованный самообучаемый алгоритм с помощью методологии ААУ позволяет получать универсальные решения, не зависящие от типа объекта трекинга, и повышает свое качество непосредственно в ходе работы. Как и в предшествующей работе предложенная на основе ААУ система не имела каких-либо предварительных настроек и оптимизаций по распознаваемым классам, как и не имела этапа предварительного обучения траекториям как такового.




Рис. 5. База знаний для примера спортивных соревнований

Выводы

Был разработан алгоритм трекинга на основании концепции ААУ [3]. Была реализована возможность адаптивного учета сложных пространственных траекторий в управлении процессом распознавания. В работе была предложена самообучаемая подсистема формирования и распознавания образов, позволяющая формировать новые образы непосредственно в течение работы системы управления. Была предложена и реализована на практике БЗ системы ААУ для задач трекинга. В результате сформированных знаний была показана возможность распознавания движущихся объектов спустя всего пару секунд после начала видеопотока (рис. 4) в процессе функционирования без предварительного обучения системы распознавания. Полученные результаты демонстрируют работоспособность концепции ААУ, а именно показывают способность к адаптации системы распознавания в режиме реального времени.

Список литературы

1. Тихонов И., Жданов А.А. Алгоритм динамического слежения за объектами в режиме реального времени // XXII Международная научно-техническая конференция «Нейроинформатика-2020» : сборник научных трудов. Москва : НИЯУ МИФИ. 2020. С. 174–183.
2. Тихонов И.В., Жданов А.А. Алгоритм извлечения знаний в системах технического зрения для задач реального времени // XXIII Международная научно-техническая конференция «Нейроинформатика-2021»: сборник научных трудов. Москва : НИЯУ МИФИ. 2021. С. 105–116.

3. Жданов А.А. Автономный искусственный интеллект: монография. Москва : БИНОМ. Лаборатория знаний. 2008. 358 с.
4. Alexey B., Chien-Yao W., Hong-Yuan M. YOLOv4: Optimal Speed and Accuracy of Object Detection // arXiv:2004.10934 [cs.CV]. 2020.
5. Mathilde C., Hugo T., Ishan M., Hervé J., Julien M., Piotr B., Armand J.: Emerging Properties in Self-Supervised Vision Transformers // Proceedings of the International Conference on Computer Vision (ICCV). 2021.
6. Liu, Ze and Lin, Yutong and Cao, Yue and Hu, Han and Wei, Yixuan and Zhang, Zheng and Lin, Stephen and Guo, Baining: Swin Transformer: Hierarchical Vision Transformer using Shifted Windows // Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV). 2021.
7. Веб сайт, url: <http://neuro-wood.com/#product> (дата обращения 16.06.2022)
8. Веб сайт, url: <https://rb.ru/longread/bdsport/> (дата обращения 16.06.2022)

НЕЙРОБИОЛОГИЯ И НЕЙРОБИОНИКА

S.V. BOZHOKIN

Peter the Great St. Petersburg Polytechnical University

NEUROCARDIOLOGY: WAVELET ANALYSIS OF HEART RATE TURBULENCE*

bsvjob@mail.ru

To analyze the turbulence of the heart rhythm, the method of wavelet analysis of a frequency-modulated signal was used, in which heart beats occur at true times separated by different cardio intervals. Criteria are formulated for finding the local frequency, which is characterized by strong heterogeneity associated with extrasystole. The behavior of the local frequency is analyzed over the entire continuous time interval both before the extrasystole and after the extrasystole. Local rate averaging over different time intervals is compared with traditional heart rate turbulence parameters such as turbulence onset and turbulence slope.

Keywords: *Heart rate turbulence, Extrasystoles, Continuous wavelet transform.*

1. Introduction

The new scientific discipline of neurocardiology, which arose at the end of the 20th century, united the efforts of cardiologists and various representatives of the neurosciences. The method of heart rate turbulence (*HRT*) allows us to quantitatively characterize short-term physiological fluctuations in the duration of sinus rhythm cardiointervals after single premature complexes – extrasystoles [1–4]. Extrasystoles are caused by the mechanism of re-entry of the excitation wave or increased oscillatory activity of cell membranes that occur in the atria, the atrioventricular node (atrioventricular node) and in various parts of the ventricular conduction system. Heart rate turbulence was first studied by G. Schmidt research team in [1]. The modern development of the *HRT* theory is presented in [3–4]. Consider the quantitative parameters of *HRT* characterizing the ventricular premature complex (*VPC*) (Fig. 1).

The extrasystole RR_{ext} is characterized by duration $RR_{ext} = 414$ ms. The

* Funding. State assignment for basic research (FSEG-2020-0024).

compensatory pause after the extrasystole RR_0 has duration $RR_0 = 1086$ ms.




Fig. 1. Electrocardiogram during extrasystole

In the *HRT* method, the change in heart rate during the extrasystole is determined by the Turbulence Onset (*TO*) parameter - relative change in the intervals between two normal heart beats (*RR*) immediately after $\{RR_1; RR_2\}$ and before *VPC* $\{RR_{-2}; RR_{-1}\}$. For the extrasystole shown in Fig. 1, the parameter $TO = -4.7\%$. The second *HRT* parameter is Turbulence Slope (*TS*). The *TS* value is the maximum positive slope of the regression line estimated for any sequence of 5 consecutive sinus intervals RR_n after *VPC*. For the rhythmogram shown in Fig. 1, the maximum value increment RR_n per beat is $TS \approx 74$ ms/Beat. Note that in the *HRT*, the duration RR_{ext} and RR_0 are not taken into account.

The purpose of the article is to develop quantitative parameters characterizing the non-stationary heart rate variability (*NHRI*), which should take into account both the time interval corresponding to the extrasystole RR_{ext} and the size of the compensatory pause RR_0 . The traditional method for studying the rhythmogram of the heart, which assumes the stationarity of the process, is the amplitude modulated signal (*AMS*) model. In the *AMS* model, different intervals between heartbeats RR_n are on an equidistant grid of times separated by intervals $\Delta t = RR_{NN}$. The value RR_{NN} is the average duration of the intervals RR_n . To analyze the non-stationary heart variability in our approach, instead of the *AMS* signal, the frequency-modulated signal (*FMS*) $Z(t)$ is used, which continuously depends on time t . For such an *FMS* signal, heart beats occur at true time points t_n , which are a non-uniform grid of times that in-

cludes both the extrasystoles and the subsequent compensatory pauses: $t_{n+1} = t_n + RR_{n+1}$, where $n = 0, 1, \dots, N-1$. Instead of the two values TO and TS , which characterize extrasystoles in the HRT model, the article introduces a time-dependent quantitative characteristic $F_{\max}(t)$, which is the variable frequency of the FMS signal.

2. Frequency-modulated signal of non-stationary rhythmogram

The FMS signal model proposed in this article $Z(t)$ is a set of identical Gaussian peaks of unit height. The centers of the Gaussian peaks t_n are on the non-uniform time grid. Time points t_n exactly coincide in time with the true moments of heart beats

$$Z(t) = \sum_{n=0}^N \exp\left(-\frac{(t-t_n)^2}{4\tau_0^2}\right). \quad (1)$$

For such a model, all identical Gaussian peaks, whose centers are separated by time intervals between heart beats RR_n , have the width of $\tau_0 = 20$ ms, coinciding with the width of the QRS heart complex. The advantage of introducing new quantitative parameters of the $NHRV$ rhythmogram becomes relevant in the study of various cardiac arrhythmias. With arrhythmias, the normal sinus rhythm is disturbed and the true moments of heart contractions that occur at time points t_n become important. The continuous wavelet transform $V(\nu, t)$ (CWT) [6–7], which maps the original signal $Z(t)$ onto the plane of continuously varying frequency ν and time parameters t , has been applied to quantify the $NHRV$ frequency-modulated signal [8–10].

In this article, the quantitative parameters of $NHRV$ analysis using FMS signal of the rhythmogram are generalized for the case of extrasystoles associated with the appearance of the ectopic focus of trigger activity, as well as with excitation re-entry occurrence (“re-entry” mechanism). The program for calculating the maximum frequency $F_{\max}(t)$, developed to establish the maximum of the continuous wavelet transform in the case of $NHRV$ analysis during various functional tests [9–10], is modified in this article to record rhythmograms with strong function heterogeneity during VPC . Such strong inhomogeneity means that the value of $F_{\max}(t)$, which is continuously dependent on time t , changes by a factor of about 2.5 during short-term VPC , for which $RR_{ext} \sim 0.4$ s, fol-

lowed by the compensatory pause of $RR_{com} \sim 1$ s. Fig. 2 shows the signal $Z(t)$ for the rhythmogram containing an extrasystole.




Fig. 2. Graph of signal $Z(t)$ depending on time t, s . Arrows show extrasystole

$RR_{ext} = 414$ ms

The continuous wavelet transform (CWT) $|V(\nu, t)|$ as a function of frequency ν and time t is shown in Fig. 3.




Fig. 3. Module of CWT $|V(\nu, t)|$ rhythmogram with the extrasystole depending on frequency ν, Hz and time t, s for the signal $Z(t)$

3. Finding the maximum frequency $F_{\max}(t)$ for rhythmogram with extrasystole

The main purpose of calculating the wavelet transform $|V(\nu, t)|$ is to find for each moment of time t the frequency $\nu = F_{\max}(t)$ at which the value $|V(\nu, t)|$ has a maximum. In case of a normal sinus rhythm, the calculation of $F_{\max}(t)$, which is characterized both by very low-frequency $VL F = (0.015; 0.04$

Hz), low-frequency $LF=(0.04; 0.15 \text{ Hz})$, and high-frequency oscillations $HF=(0.15; 0.4 \text{ Hz})$, is not difficult [9-10]. However, analysis of the *CWT* (Fig. 3) shows complex behavior of the local frequency $\nu = F_{\max}(t)$, which determines the maximum value $|V(\nu, t)|$ at a time point t near the time point $t > 1.4 \text{ s}$. At this point in time, the extrasystole $R_{ext}=0.414 \text{ s}$ is observed. Let us formulate the algorithm for finding the value $F_{\max}(t)$ for the rhythmogram with extrasystoles. First, from the known values of RR_n we calculate the corresponding frequencies $f_n = 1/RR_n$, where the quantities f_n are measured in *Hz*, and the quantities RR_n are measured in seconds. Our first assumption is that in the time interval t satisfying the relationship $t_{n-1} \leq t < t_n$, where $t_n - t_{n-1} = RR_n$, the value $F_{\max}(t)$ determined by establishing the *CWT* maximum $|V(\nu, t)|$ should be approximately equal to $F_{\max}(t) \approx 1/RR_n$. However, if there are other heart beats RR_k with smaller magnitudes next to such a heart beat, then the behavior of the maximum frequency $F_{\max}(t)$ will also depend on the neighboring heart beats. Let us expand the limits of finding the maximum $f_n^{\max}$ and minimum $f_n^{\min}$ discrete frequency in n the time interval. In this case, the upper discrete boundary $f_n^{\max}$ and the lower discrete boundary $f_n^{\min}$ can be determined from the relation

$$f_n^{\max} = [1 + B(RR_n)] f_n; \quad f_n^{\min} = [1 - A] f_n \quad (2)$$

Note that the upper limit of the frequency search corridor $f_n^{\max}$ depends on the value of $RR_n(s)$. By analyzing various extrasystoles, it can be shown that the value $B(RR_n)$, which is a relative excess $f_n^{\max}$ over the value f_n , has the form

$$B(RR_n) = B_{\min} + \frac{B_{\max} - B_{\min}}{1 + \exp\left[-\frac{(RR_n - RR_{cr})}{\tau_{RR}}\right]}; \quad (3)$$

where $B_{\min}=0.001$; $B_{\max}=0.21$; $RR_{cr}=0.840 \text{ s}$, $\tau_{RR}=0.12 \text{ s}$. Thus, for heart beats of short duration, $RR_n \leq RR_{ex}$, the upper search limit $f_n^{\max}$ for a continuous value $F_{\max}(t)$ slightly exceeds the frequency $f_n = 1/RR_n$, $f_n^{\max}/f_n =$

$= 1.001$. For heart beats with large values of $RR_n > 1.4$ s, the upper discrete search limit tends to $f_n^{\max} / f_n = 1.21$. The lower limit A of the search for the maximum frequency $F_{\max}(t)$, which characterizes the difference $f_n^{\min}$ from f_n , is a constant value $A = 0.25$. Relations (2)-(3), which define discrete boundaries $f_n^{\max}$ and f_n search for a continuous frequency $F_{\max}(t)$, work for all heart beats RR_n , except for the case of the extrasystole $RR_k = RR_{ext} = 0.414$ s. This is because after the extrasystole, which has the number k , a compensatory pause occurs with the number $k+1$, for which $RR_{k+1} = 1.086$ s reaches a large value. This results in the ratio of adjacent frequencies reaching a large value of $f_k / f_{k+1} = RR_{k+1} / RR_k = 2.6$. Such a large frequency jump also occurs before extrasystole $RR_{k-1} = 0.727$ s, with $f_k / f_{k-1} = RR_{k-1} / RR_k = 1.76$. Therefore, for two spaces adjacent to the extrasystole $n = k-1$, and $n = k+1$, both the upper limit of the search for maximum $f_{k\pm 1}^{\max}$ and minimum frequencies $f_{k\pm 1}^{\min}$, should be expanded. In Fig. 4, the asterisks mark the value of discrete frequencies $f_n = \frac{1}{RR_n}$, which correspond to the times $t_n + \frac{RR_n}{2}$, where $n = 0, 1, \dots, N-1$. The smooth line marks the behavior of the maximum frequency $F_{\max}(t)$ depending on time t for the rhythmogram with extrasystole (Fig. 2).




Fig. 4. Asterisks mark the time dependence of discrete frequencies $f_n = 1/RR_n$ at times $t_n + RR_n/2$. The dependence of the function $F_{\max}(t)$ on time is shown as a continuous line

Using the function $F_{\max}(t)$ we can establish the values of TS and TO

$$TS = -1000 \left\langle \frac{1}{F_{\max}^2} \frac{dF_{\max}}{dt} \right\rangle / \left\langle \frac{1}{F_{\max}} \right\rangle;$$

$$TO = 100\% \left(\left\langle \frac{1}{F_{\max}(t)} \right\rangle_2 - \left\langle \frac{1}{F_{\max}(t)} \right\rangle_1 \right) / \left\langle \frac{1}{F_{\max}(t)} \right\rangle_1. \quad (4)$$

The bracket symbol $\langle \rangle$ means the sign of averaging over a certain period of time $t \approx 3$ s after the compensatory pause RR_0 (Fig. 2). Calculation of TS using formula (4) gives the value for $TS \approx 82$ ms/Beat. This value is very close to that of $TS \approx 74$ ms/Beat, which was calculated by the traditional method of finding the maximum value for the heart rate increment within 5 beats after the RR_0 . In this expression (4) for TO , the symbol $\langle \rangle_1$ means averaging over a period of time equal to two beats before the extrasystole, and the symbol $\langle \rangle_2$ means averaging over a period of time equal to two beats after the RR_0 . Calculation by formula (4) also gives a value $TO \approx -4.3\%$, which is approximately equal to the traditional value $TO \approx -4.7\%$.

4. Conclusion

To analyze the non-stationary $NHRV$ rhythmogram, we used the FMS signal $Z(t)$ instead of the AMS signal $RR_n = RR(t_n)$, where t_n is a uniform grid of time points $t_n = n \cdot RRNN$, $n = 1, 2, \dots, N$. The signal $Z(t)$ is a superposition of identical Gaussian peaks versus continuous time t . The centers of the Gaussian peaks are located at the uneven grid of times and coincide with the true moments of heart beats: $t_0 = 0$; $t_{n+1} = t_n + RR_{n+1}$. The maximum CWT , which depends on frequency ν and time t , allows calculating the dependence of the local frequency $F_{\max}(t)$ for such a frequency-modulated signal. The quantitative characteristic of HRT has been developed, which takes into account both the duration of the extrasystole itself RR_{ext} and that of the compensatory pause RR_0 following the extrasystole. This characteristic is the behavior of the local frequency $F_{\max}(t)$, which is calculated over the entire continuous time interval both before and after the extrasystole. The traditionally used HRT parameters TO and TS are compared with the values calculated by averaging $F_{\max}(t)$. The

proposed method for calculating the parameter $F_{\max}(t)$ can be used to analyze the non-stationary rhythmogram both at rest and during various functional tests for patients with normal sinus rhythm and those suffering from congestive heart failure, atrial fibrillation, ventricular fibrillation, preventive contraction, left bundle branch block, ischemic/dilated cardiomyopathy and sick sinus syndrome.

References

1. Schmidt G., Malik M. [et al.]. Heart-rate turbulence after ventricular premature beats as a predictor of mortality after acute myocardial infarction // *The Lancet*. 1999. V. 353. P. 1390–1396.
2. Bauer A., Malik M. [et al.]. Heart rate turbulence: Standards of measurement, physiological interpretation, and clinical use: International society for holter and noninvasive electro- physiology consensus // *Journal of the American College of Cardiology*. 2008. V. 52(17). P.1353–1365.
3. Watanabe M.A.: Heart rate turbulence: a review. *Indian pacing and electrophysiology journal* 3(1), 10–22 (2003) PMID: PMC1555628 PMID: [16943986](#).
4. Blesius V., Schölzel C., Ernst G., Dominik A. HRT assessment reviewed: a systematic review of heart rate turbulence methodology // *Physiological Measurement*. 2020. 41(8), 08TR01.
5. Al-Zaiti S.S., Pietrasik G. [et al.]. The role of heart rate variability, heart rate turbulence, and deceleration capacity in predicting cause-specific mortality in chronic heart failure. *Journal of electrocardiology*. 2019. V. 52. P. 70–74.
6. Mallat S., *A Wavelet Tour of Signal Processing*. 3rd ed. New York : Academic Press, 2008.
7. Addison P.S., *Wavelet transform and the ECG: review* // *Physiol. Meas.* 2005. V. 26. R155–R199.
8. Bozhokin S.V., Sokolov I.M. Comparison of the Wavelet and Gabor Transforms in the Spectral Analysis of Nonstationary Signals // *Tech. Phys.* 2018. V. 63. P. 1711–1717.
9. Bozhokin S.V., Suslova I.B. Analysis of non-stationary HRV as a frequency modulated signal by double continuous wavelet transformation method // *Biomedical Signal Processing and Control*. 2014. V. 10. P. 34–40.
10. Bozhokin S.V., Lesova E.M., Samoilov V.O. [et al.]. Nonstationary Heart Rate Variability during the Head-Down Tilt Test. *Biophysics*. 2020. V. 65. P. 151–158.

Г.С. ВОРОНКОВМосковский государственный университет имени М.В. Ломоносова
av13675@yandex.ru**НЕИЗВЕСТНАЯ ХАРАКТЕРИСТИКА ФЕНОМЕНА «КУБ
НЕККЕРА»: ДВА 3D ОБРАЗА КУБА ЗЕРКАЛЬНЫ
ДРУГ ДРУГУ**

В работе описывается ранее неизвестная характеристика зрительного феномена «Куб Неккера» (фКН), именно, что два трехмерных (3D) образа куба, попеременно видимые в «плоском» КН, зеркальны в отношении друг друга. Анализ фКН в этом аспекте позволил составить представление о нейронной модели, репрезентирующей в монокулярной зрительной системе 3D зрительное пространство; это сделало возможным описать «механизм» фКН в нейрофизиологических терминах. Обсуждается возможность феномена, подобного зрительному фКН, в мышлении.

Ключевые слова: *зеркальные/вывернутые наизнанку образы, нейронная модель зрительного пространства, фактор зеркальности в мышлении.*

Введение

«Куб Неккера» – феномен (фКН), относящийся к группе зрительных феноменов-иллюзий, имеющей несколько наименований: «картинки перевертыши», «двойственные = двойные = амбивалентные = альтернативные картинки» [1–4]; фКН состоит в попеременном видении в «плоском» изображении куба то одного трехмерного (3D), то другого, тоже 3D, но иначе видимого, куба. «Знаменитым», как стали называть этот феномен, сделали его большая наглядность и явно проявляемая связь его с мышлением. Именно последний аспект явился основным при обсуждении фКН в литературе. Из проведенного анализа [1–3], а также прямых данных [5] следовало, что для видения двух 3D образов куба в «плоском» КН субъекту необходим некоторый объем зрительного опыта и знаний, полученных в результате предварительного обучения.

В предлагаемой здесь работе описывается и анализируется другая характеристика фКН, именно, что два 3D образа куба, попеременно видимые в «плоском» КН, зеркальны в отношении друг друга. Попытка автора найти в литературе работу, содержащую это утверждение, оказалась тщетной. В вышеназванных источниках также не используются термины «зеркальный», «зеркальное преобразование» и другие, связанные с поня-

тием «зеркальная симметрия». В то же время используется термин «вывернутый наизнанку куб» [3]. Согласно автору настоящей работы (см. Основной текст), «вывёртывание объекта наизнанку» есть, в сущности, «зеркальное преобразование», или, другими словами, вывертывание наизнанку есть один из способов преобразования объекта (оригинала) в зеркальный ему объект (зеркальную модель оригинала); это справедливо, по крайней мере, в отношении 1D, 2D и 3D объектов. Если следовать такому пониманию термина «вывернутый куб», то, казалось бы, это свидетельствует о признании того, что оба 3D образа КН являются «зеркальными друг другу». Однако попытка автора найти в этой [3] и других работах текст, содержащий в явном виде такое же понимание термина «вывернутый», тоже оказалась безуспешной. Кроме того, вместо термина «вывернутый» некоторые авторы, например [4], используют термин «повернутый», не несущий значение «вывернутый». Эти обстоятельства обусловили автора предлагаемой здесь работы выбрать тему **«зеркальность по отношению друг к другу видимых 3D образов в «плоском» КН»** в качестве приоритетной – этой теме посвящен Основной текст работы, эта тема вынесена также в заголовок работы.

Поскольку предлагаемая работа направлена, в конечном итоге, на установление корреляции **пространственных** характеристик **нейронной модели**, репрезентирующей 3D зрительное пространство, с таковыми его субъективного **зрительного образа**, в работе **составлено представление** о такой (3D) нейронной модели, и уже в нейрофизиологических терминах описывается «механизм», обуславливающий фКН. Это представление изложено в разделе Обсуждение; кроме того, здесь обсуждается возможность феномена, подобного (в принципе) зрительному фКН, в абстрактном мышлении.

Отметим также важный факт, кратко описываемый в разделе Основной текст, – для проявления фКН, как и для других феноменов из группы «двойственные картинки», достаточно **монокулярного** зрения.

Данная работа продолжает и развивает работы автора, касающиеся зрения и мышления, в частности [6–8], где термин «зеркальная симметрия» и производные от него термины (зеркальность, фактор зеркальности, зеркальное соответствие и другие) являются ключевыми.

Основной текст

Описание феномена «Куб Неккера» (фКН). На рис. 1А дано изображение «плоского» КН. Это изображение относится к серии так называемых «двойственных картинок» потому, что человек видит в нём, благодаря

ранее полученному зрительному опыту (знакомству с объектом «куб») и полученным знаниям (о законах перспективы в изображении 3D мира), попеременно два разных (альтернативных) **3D образа** куба (В и С). Описан случай, прямо подтверждающий необходимость предварительных опыта и знаний для проявления фКН: ослепший в младенчестве и прозревший лишь в зрелом возрасте пациент (некто Сидни Брэдфорд) не был способен видеть в «плоском» КН 3D образы В и С [5].




Рис. 1. «Плоский» куб Неккера (А) и попеременно видимые в нём два (В и С) трехмерных образа куба. Для облегчения видения разных образов куба: «закрытые» гранями ребра кубов В и С изображены пунктиром; «сделаны» непрозрачными верхняя грань у куба В и нижняя грань у С; дальняя вершина (g) у В обведена малой окружностью; она же (g) у С, видимая уже на переднем плане, обведена большой окружностью

В литературе, при сравнении этих альтернативных образов куба, отмечается, как правило, факт, что стенка (грань), видимая как задняя в одном образе, видится как передняя в другом, и что один куб видится как повернутый другой, альтернативный ему куб. Действительно, на рис. 1 грань куба В с левой нижней вершиной g является задней гранью куба, тогда как в кубе С она является передней; при этом куб С видится как повернутый куб В (и наоборот). Однако эта констатация ещё не описывает фКН полностью; отметим здесь еще некоторые, важные для последующих анализа и обсуждений, его аспекты.

1. Если бы куб С (на рис. 1) был кубом В, просто повернутым к нам задней гранью, то его вершина g находилась бы справа; она же находится слева. Таким образом, куб С не есть просто повернутый к нам задней гранью куб В.
2. Для видения **двух 3D** образов в «плоском» кубе Неккера, так же как и в других двойственных картинках (к примеру, в картинках «лестница», «сложенный пополам лист бумаги» и других [1, 2]),

достаточно **монокулярного** зрения. В этом легко может убедиться самостоятельно каждый, рассматривая эти картинки одним глазом.

3. Два 3D куба, В и С, обращены к нам под разными углами. Так, В «смотрит» влево, другой – вправо; В видится немного сверху, другой – снизу; эти углы видения можно изменить до «наоборот» – для этого достаточно изменить угол изображения боковых ребер в «плоском» КН.

Как уже отмечено выше, в работе рассматривается и обсуждается фКН только в аспекте фактора зеркальности; аспект 3 не рассматривается.

Куб С зеркален кубу В (и наоборот). Чтобы доказать это утверждение, достаточно показать, например, (1) что куб С идентичен зеркальному отображению куба В или (2) что собственная система координат куба С зеркальна таковой куба В, то есть, что из трех пар одноименных осей у одной пары оси направлены противоположно (это, как мы увидим на рис. 2, соответственно, пары ge-ge, gh-gh, gc-gc и пара gc-gc).

Рассмотрим вариант (1). На рис. 2 кубы В и С идентичны кубам В и С на рис. 1 соответственно. Вершины этих (В и С) кубов (а также куба D), идентичные вершинам «плоского» КН (рис. 1А), обозначены буквами a, b, c, d, e, f, g, h – подобно вершине, обозначенной буквой g на всех кубах на рис. 1. Куб D (на рис. 2) есть куб С, который перенесен и поставлен (сохраняя переднее положение грани gefh) на свою нижнюю грань напротив куба В так, чтобы ребра gc и cg (кубов D и В соответственно) находились на одной прямой линии. Таким образом, куб D есть, фактически, тот же куб С, но рассматриваемый теперь под другим углом (ракурсом) – таким же, что и куб В. Другими словами, куб D идентичен кубу С.

Куб В есть точная копия отображения куба D в поставленном перед ним (перед кубом D) зеркале, как это изображено на этом же рис. 2. Действительно, лицевая грань sabd куба В видится как «отпечаток» грани sabd куба D, то есть так, как в зеркале. Зеркальными (по отношению к таковому куба D) видятся и другие соответствующие грани и ребра куба В. (В этом легче всего убедиться непосредственно, на опыте, т.е. нарисовать куб D так, чтобы его лицом была грань dbac; обозначить его вершины, как на рис. 2, D и отобразить изображение в обычном зеркале, как на рис. 2. Далее, сравнить отображение в зеркале с кубом В. Отображение будет идентичным кубу В; это и будет свидетельствовать, что куб D зеркален кубу В). Таким образом, куб В зеркален кубу D (и наоборот). В то же время поскольку куб D идентичен кубу С, то куб В зеркален и кубу С (и наоборот – куб С зеркален кубу В).

Рассмотрим вариант (2). Построим ортогональные системы координат для кубов D и B (рис. 2.) с центром в вершине g и соответствующими одноименными осями (gc, gh и ge). Можно видеть, что в паре вертикальных осей (ge и ge) и в паре горизонтальных осей (gh и gh) оси направлены одинаково, а в паре осей глубины (gc и gc) оси направлены навстречу друг другу. Если повернуть эти два объекта так, чтобы совместились по направлению оси в двух других парах одноименных осей, то навстречу направленными окажутся оси в другой, «оставшейся» паре. Встречная направленность осей в какой-либо паре одноименных осей (у одноименных систем координат двух объектов, связанных отношением оригинал-модель) есть свидетельство зеркальности этих объектов в отношении друг друга. Таким образом, показано (двумя способами), что видимые в «плоском» КН два 3D образа куба являются зеркальными в отношении друг друга.

Куб С есть вывернутый наизнанку куб В (и наоборот). Определению «вывернутый наизнанку» наиболее соответствует, видимо, тот легко всем доступный для наблюдения факт, что после вывертывания 3D объекта наизнанку его стороны, бывшие внутренними, становятся наружными (пример – вывернутая наизнанку рукавица).

То же можно сказать в отношении 2D (двумерного) объекта: двумерный объект, рассматриваемый с обратной стороны (на просвет), есть вывернутый наизнанку объект – ибо при этом его бывшая внутренняя (обратная) сторона становится наружной (лицевой).

Изменение порядка точек в линии на обратный порядок есть вывертывание наизнанку 1D (одномерного) объекта.

Для всех трех случаев (1D, 2D и 3D) не имеет значения, каким способом происходит само превращение (преобразование, отображение, создание, формирование) объекта в «вывернутый наизнанку» по отношению к оригиналу (механическим, оптическим, программным или другим) – всегда у вывернутого наизнанку объекта его наружные стороны – это бывшие внутренними (у оригинала) стороны. Соответствует ли такое понимание термина «вывернутый» случаю с фКН? Сравним одноименные грани кубов В и С (рис. 2). Грань $sabd$ куба В является передней и обращена к нам наружной стороной; в кубе С эта же грань, $sabd$, является задней и её сторона, бывшая наружной в кубе В, является теперь, как можно видеть, внутренней стороной. Боковые, а также верхняя и нижняя грани при «переходе» от куба В к кубу С остаются на прежних местах, однако их внутренние стороны становятся при этом «переходе» наружными (и наоборот) – это видно при «прочтении» вершин каждой грани: например, левая бо-

ковая грань куба В прочитывается с внутренней стороны как саег; в кубе же С (и идентичном ему кубе D) при тех же условиях (то есть тоже с внутренней стороны) она




Рис. 2. Иллюстрация к выводу, что альтернативные 3D образы куба Неккера (В и С) являются зеркальными друг другу. Описание в тексте



Рис. 3. Левая рукавица после вывертывания наизнанку становится правой, то есть зеркальной левой рукавице. Видно (по цвету), что внутренняя сторона левой рукавицы стала внешней у правой. См. текст

прочитывается уже как геас, то есть как наружная сторона у куба В. Другими словами, левая грань куба D (=C) есть повернутая на 180° вокруг вертикальной оси левая грань куба В. Аналогичный поворот происходит, как можно видеть, и у остальных граней (другой боковой, верхней и нижней). Такой поворот на 180° у 2D объекта (грани) есть вывертывание его наизнанку (см. выше). Таким образом, здесь показано, что два 3D образа куба, видимые в «плоском» КН, являются вывернутыми наизнанку по отношению друг к другу.

В то же время оба эти куба (В и С) являются, как показано выше, также зеркальными в отношении друг друга. Можно показать, что вывернутому наизнанку объекту **всегда** присущи характеристики **зеркально** преобразованного объекта. Простой, уже упомянутый выше, наглядный пример этому – вывертывание наизнанку рукавицы (рис. 3): вывертывание происходит в данном случае вдоль оси Z (как и в случае «вывертывания» куба В в куб D); после вывертывания ось Z имеет обратное направление, чем до вывертывания; после же совмещения по направлению осей в паре Z (путем поворота рукавицы) направленными навстречу друг другу становятся уже оси пары X – можно видеть, что ось X у системы координат вывернутой (ставшей правой) рукавицы направлена навстречу оси X левой рукавицы; это является свидетельством зеркальности рукавицы после вывертывания по отношению к рукавице-оригиналу. Из сделанного здесь описания очевидно, что вывертывание наизнанку есть лишь один из способов зеркального преобразования.

Обсуждение

Представление о нейронной модели, репрезентирующей реальное зрительное 3D пространство¹ в монокулярной зрительной системе. Пространственные характеристики зрительных 3D объектов наиболее полно представлены («смоделированы»), по-видимому, только их **субъективными** 3D образами – ибо только образ гомотетичен своему оригиналу, он как бы проецируется на него и сливается с ним. В отличие от образа, **нейронное представительство** (=нейронная модель) зрительного объекта не является гомотетичным². Тем не менее, пространственная характеристика образа – его зеркальность (в отношении исходного оригинала) – полностью **зависит** от зеркальности, предшествующей образу **2D нейронной модели** исходного оригинала³. Факт наличия этой зависимости дает основание полагать (учитывая изложенное в Основном тексте),

¹ Монокулярное зрительное пространство – это видимое одним глазом реальное пространство, ограниченное, как рамкой, глазницей и краем носа, при фиксированной голове [9].

² Ибо, к примеру, извилистость мозговой коры не соответствует свойству нейронной модели «быть гомотетичной».

³ Чтобы убедиться в этом, достаточно заменить **оптическую топографическую проекцию (ОТП)**, которая предшествует нейронной топографической проекции (НТП), на зеркальную ОТП, например, посмотрев на мир в обычном зеркале. (ОТП поля зрения создается на сетчатке оптикой глаза; НТП сетчатки есть, образно говоря, нейронный отпечаток ОТП; она представлена также в зрительных центрах мозга [10]).

что зеркальность образа может зависеть также и от третьего (предполагаемого в данной работе) измерения нейронной модели – её оси глубины (точнее, от направления этой оси). Ниже описывается представление о предполагаемых нейронных 3D моделях, соответственно, 3D поля зрения и 3D зрительного пространства.

Это **представление** основано на известном нейроанатомическом факте, – что в центрах зрительного мозга млекопитающих, в том числе человека, НТП (см. сноску 3) является многослойной [10]. Половина из этих слоев получает волокна только от одного глаза, т.е. эти слои являются монокулярными. Согласно **представлению**, каждый такой нейронный слой НТП поставлен в соответствие только «своему» фронтальному слою поля зрения; зрительная система сама «разбивает» глубину поля на эти, следующие друг за другом, фронтальные слои. Количество последних равно количеству монокулярных нейронных слоев НТП и не зависит от глубины самого поля. Соответствие между нейронными слоями, с одной стороны, и слоями поля, с другой, а также выбор начала (места) «разбиения» поля на фронтальные слои осуществляется механизмом выбора (внимания), управляющего зрением. В первом слое НТП представлена информация об объектах (точках) 1-го слоя поля; во втором – о точках 2-го и т.д. Таким образом, в этом представлении, глубину (ось Z) реального поля зрения представляет последовательность из его 2D фронтальных слоев, а его 3D **нейронная модель в целом** представлена соответствующими им 2D слоями НТП.

Далее, в работе допускается, что **нейронная модель зрительного пространства** (НМЗП) организована так же, из последовательности 2D нейронных слоев, как НТП. Это представление позволяет представить и описать «механизм» фКН на нейронном уровне. Действительно, от того, какая фронтальная грань, *cabd* или *gefh* (рис. 2B и C), проецируется в первый слой НМЗП, зависит направление оси глубины у попеременно формируемых 3D **нейронных** кубов B и C и, следовательно, их зеркальность (см. Основной текст). В «плоском» КН (рис. 1A) информация (для системы внимания) не является достаточной, однозначной, чтобы определить (выбрать), какая из граней, *cabd* или *gefh* (рис. 2), соответствует первому слою НМЗП. Поэтому процесс выбора оказывается в значительной степени случайным. Это и обуславливает **попеременное** (либо то, либо альтернативное ему другое) формирование зеркальных друг другу 3D **нейронных моделей куба** и, как следствие этого, зеркальных друг другу 3D образов КН, то есть фКН.

Мышление и фКН. Будучи тесно связанным с мышлением (как отмечено выше), фКН выступает как еще одно свидетельство важности понятия фактор зеркальности в мышлении (дополняющее таковые, приводимые в работе [8]). Действительно, фКН наглядно свидетельствует, что если у одного субъекта доминирует (по каким-то обстоятельствам или даже намеренно) какой-то один из двух образов КН (допустим, В), а у другого - вывернутый наизнанку образ этого куба (куб С; рис. 2), то этим субъектам будет трудно прийти к согласию в описании того, каким на самом деле является исходный объект-оригинал (информация о котором находится у них перед глазами), так как каждый из этих субъектов будет уверен (или «уверен») **в очевидности** правоты своего описания, ибо, как уже отмечалось [8], невозможно доказать, какая модель (из двух зеркальных друг другу) адекватна (тождественна) своему оригиналу, если информация об оригинале не может быть воспринята однозначно.

Как показано в этой же работе [8], функциональные проявления фактора зеркальности имеют место и в случаях абстрактного мышления. Это даёт основание предполагать, что в ситуациях, сходных, в принципе, с обстоятельствами, приводящими к зрительному фКН (дефицит информации и/или неоднозначность её восприятия), подобный феномен и его следствия могут иметь место и в абстрактном мышлении⁴.

Знание о характеристиках проявлений и природе фКН – условие для распознавания его и, возможно, управления им в процессах восприятия.

Заключения и выводы

1. Показано, что два попеременно видимые в «плоском» КН 3D образа куба являются **зеркальными, вывернутыми наизнанку** по отношению друг к другу.
2. Зеркальность **субъективного 3D образа** объекта-оригинала, в том числе образов в фКН, зависит от зеркальности **нейронной 3D модели** объекта-оригинала, обуславливающей этот образ.
3. Согласно составленному в работе **представлению**, в монокулярной зрительной системе **нейронная 3D модель** реального 3D зрительного пространства состоит из последовательности 2D нейронных слоев, соответствующих следующим вглубь, друг за другом фронтальным слоям этого пространства.
4. **Механизмы** зеркального преобразования, подобные **статичным нейроанатомическим механизмам** в зрительном пути [6, 7], в случае

⁴ В случае с ментальным пространством, роль оси глубины играет, по-видимому, ось (+) / (-) оценки.

фКН отсутствуют, ибо причиной («механизмом») попеременной зеркальности у образа в этом случае является работа управляющего взором **динамичного механизма внимания**.

5. Зеркальность **нейронной 3D модели** воспринимаемого объекта-оригинала обуславливается (в случае фКН) тем, от какой из двух фронтальных граней «плоского» КН воспринимается информация первым слоем **нейронной 3D модели** 3D зрительного пространства.
6. Пример фКН наглядно свидетельствует о принципиальной невозможности выяснить по двум зеркальным друг другу моделям (образам) оригинала, каков сам оригинал, если воспринимаемая зрительная информация об оригинале неоднозначна. В работе допускается возможность феномена, подобного фКН, в мышлении, когда значения (особенно ценностные) воспринимаемых терминов неконвенционны.

Список литературы

1. Грегори Р.Л. Разумный глаз. – Москва : Мир, 1972. – 209 с.
2. Хакен Г., Хакен-Крелль М. Тайны восприятия. – Москва : Институт компьютерных исследований, 2002. – 272 с.
3. Демидов В.Е. Как мы видим то, что видим. – Москва : Знание, 1987. – 240 с.
4. Грегг Дж. Опыты со зрением. – Москва : Мир, 1970. – 200 с.
5. Gregory R. The Blind Leading the Sighted: An Eye-Opening Experience of the Wonders of Perception // Nature. – 2004 – 7002, N 430. P. 836.
6. Воронков Г.С. Инверсия сетчатки и перекресты зрительных волокон как нейроанатомические механизмы зеркальных преобразований // Вестник московского университета. Серия 16. Биология. 2009. № 4. С. 8–13.
7. Воронков Г.С. Зеркальные преобразования топографических проекций полей зрения: роль инверсии сетчатки и перекрестов зрительных волокон. //XIII всероссийская научно-техническая конференция «Нейроинформатика-2011»: Лекции по нейроинформатике. – Москва : НИЯУ МИФИ, 2010. С. 218–270.
8. Воронков Г.С. Фактор зеркальности в зрении и мышлении: морфологические и функциональные проявления. //XXIII Международная научно-техническая конференция «Нейроинформатика-2021»: Сборник научных трудов. – Москва : НИЯУ МИФИ, 2021. С. 78–87.
9. Логвиненко А.Д. Зрительное восприятие пространства. – Москва : Изд-во Моск. ун-та, 1981. – 224 с.
10. Супин А.Я. Нейрофизиология зрения млекопитающих. – Москва : Наука, 1981. – 252 с.

**В.А. ЛЯХОВЕЦКИЙ¹, Д.Д. МОРОЗОВ², П.Е. МУСИЕНКО^{1,3},
Н.С. МЕРКУЛЬЕВА^{1*}**¹Институт физиологии им И.П. Павлова РАН, Санкт-Петербург, Россия²École polytechnique, Paris, France³Институт трансляционной биомедицины СПбГУ, Санкт-Петербург, Россия

*mer-natalia@yandex.ru

**НЕЛИНЕЙНАЯ ДИНАМИЧЕСКАЯ МОДЕЛЬ СИСТЕМЫ
ГЕНЕРАТОРОВ РИТМА ШАГАНИЯ***

Рассматривается проблема моделирования синхронизации ритмов центральных генераторов паттерна локомоции, возникающая при одновременно двунаправленной ходьбе, вызываемой электрической эпидуральной стимуляцией. Предложена нелинейная динамическая система генераторов ритма ходьбы, основанная на осцилляторах Ван-дер-Поля. Результаты моделирования обсуждаются в контексте знаний о нейрональных структурах спинного мозга млекопитающих.

Ключевые слова: *центральный генератор паттерна, локомоция, осциллятор Ван-дер-Поля.*

Введение

Моторный репертуар животных включает ряд достаточно стереотипных, «автоматических», движений, таких как дыхание, жевание, глотание и различные виды локомоции. В многочисленных экспериментах, выполненных на изолированном спинном мозге беспозвоночных и низших позвоночных животных, а также на млекопитающих, было обнаружено, что изолированные нервные центры сохраняют способность генерировать моторный выход, лежащий в основе таких движений. На основе этих данных было сформулировано понятие центрального генератора паттерна (ЦГП), определяемого как совокупность взаимосвязанных нейронов, способных генерировать основную картину моторного выхода, лежащего в основе данного движения, в отсутствие афферентных сигналов от исполнительного двигательного аппарата.

Математические модели ЦГП могут принадлежать различным классам. Например, в [1] предложена модель, в которой рассматриваются потенциальные силы, действующие на относительные фазы осцилляторов.

* Работа поддержана грантом РНФ № 21-15-00235.

Потенциалы этих сил имеют минимумы в некоторых положениях, отвечающих за шаг, рысь, галоп. В работе [2] была предложена принципиально иная модель, описывающая непосредственно нейроны и токи в них, используя ряд существенных упрощений. Также существуют работы, в которых для описания ЦГП применяют уравнения Ван-дер-Поля, которые широко используются при описании динамики работы электротехнических схем, химических реакций, а также колебаний численности биологических популяций. Например, в [3] была представлена модель ЦГП для робота-сороконожки, в которой каждая нога была связана с предыдущей, а первая – с последней, а в [4] была предложена модель, использующая модифицированное уравнение Ван-дер-Поля для моделирования ЦГП робота с четырьмя конечностями.

Как правило, модели ЦГП строятся для имитации особенностей однонаправленной ходьбы вперед. Однако известно, что животные, в том числе и человек, способны и к ходьбе назад, и даже к одновременной двунаправленной ходьбе (ОДХ), при которой одна конечность идет вперед, а другая в то же время – назад. Более того, возможно вызвать ОДХ децереброванного животного за счет активации спинальных нейрональных механизмов путем электрической эпидуральной стимуляции дорсальной поверхности спинного мозга [5]. Можно предположить, что такая электрическая стимуляция в одинаковой степени должна влиять на все ЦГП, то есть на все уравнения системы. Между тем, в большинстве известных нам работ, посвященных системе уравнений Ван-дер-Поля, функция, выводящая систему из равновесия (возмущающая функция), отсутствует или относится лишь к одному из уравнений системы (см. таблицу, обозначения аналогичны системе (1)).

Таблица

Модификации системы уравнений Ван-дер-Поля

Работа	Функции связи	Возмущающая функция	Комментарий
[6]	$\begin{cases} \gamma(\dot{y} - \dot{x}) \\ \gamma(\dot{x} - \dot{y}) \end{cases}$	$\begin{cases} C \cos wt \\ 0 \end{cases}$	Исследовали квазипериодическое приближение. Получен аналитический ответ и проведен электротехнический пример реализации уравнения.
[7]	$\begin{cases} \gamma_1(\dot{y} - \dot{x}) \\ \gamma_2(\dot{x} - \dot{y}) \end{cases}$	$\begin{cases} C_1 \cos t \\ C_2 \cos t \end{cases}$	Проведен анализ решений на основе электротехнических схем, а также разобраны примеры схем для одиночных уравнений Ван-дер-Поля.

[8]	-	$\begin{cases} C \cos wt \\ C \cos wt \end{cases}$	Не рассматривали уравнение Ван-дер-Поля в классическом виде, но в качестве экспериментальной модели использовалась схожая схема. Также получили диаграмму бифуркаций для возмущенной системы.
[9]	$\begin{cases} \gamma(\dot{y} - \dot{x}) \\ \gamma(\dot{x} - \dot{y}) \end{cases}$	$\begin{cases} C \cos wt \\ 0 \end{cases}$	Изучали осцилляторы с малым различием собственных частот.
[10]	$\begin{cases} \gamma(\dot{y} - \dot{x}) \\ \gamma(\dot{x} - \dot{y}) \end{cases}$	$\begin{cases} 0 \\ 0 \end{cases}$	Разобрано новое взаимодействие, которое, однако, не подходит для физической системы, рассмотренной далее, из-за нарушения размерностей в функции связи.

Исключением является [7], в которой возмущающая функция одинакова для двух уравнений. Однако в [7] не исследована возможность синхронизации системы при различных для каждого из уравнений частотах колебаний, а известно, что частота однонаправленной ходьбы вперед и назад для децеребрированного животного различна [5]. Задача могла бы допускать квазигармоническое приближение в случае быстрого установления стабильного режима ходьбы. Однако характерное время установления режима ходьбы составляет величину порядка периода колебаний (т.е. его длительность составляет один или несколько последующих шагов животного [11]), что означает необходимость рассмотрения не квазигармонического приближения.

Целью работы было создание модели синхронизации двух осцилляторов во время ОДХ, обусловленной эпидуральной стимуляцией.

Постановка задачи и реализация алгоритма

Как было показано ранее, координированная реципрокная мышечная активность двух конечностей определяется сенсорным входом, а именно направлением движения лент тредбана [5]. При моделировании необходимо учитывать, что частоты w_1 и w_2 осцилляторов при ОДХ имеют разные знаки. Теорема, предложенная в [1], гласит, что все осцилляторы в системе должны иметь одинаковую динамику. Чтобы удовлетворить это требование, уравнения системы связанных осцилляторов должны включать их частоты не в первой, а во второй степени. Хорошо известной динамической системой, удовлетворяющей этому требованию, является система осцилляторов Ван-дер-Поля. Мы обобщили подход, предложенный в [12] для моделирования одного осциллятора, на их систему, возбуждаемую внешним периодическим сигналом (эпидуральной стимуляцией).

$$\begin{cases} \ddot{x} + \tau(\varepsilon - x^2)\dot{x} + w_1^2 x + \gamma(\dot{y} - \dot{x}) = Bf(wt) \\ \ddot{y} + \tau(\varepsilon - y^2)\dot{y} + w_2^2 y + \gamma(\dot{x} - \dot{y}) = Bf(wt) \end{cases}, \quad (1)$$

где τ и ε – характеристики торможения системы, τ также зависит от силы тока, γ – характеристика связи между конечностями, B и w – амплитуда и частота периодического дельтаобразного сигнала $f(t)$, симулирующего возмущение системы периодической стимуляцией, в равной степени активирующей оба ЦГП. Динамика осцилляторов исследовалась численно в вычислительной среде Matlab R2016b с помощью метода среднего порядка (ode45). Дельтаобразная функция моделировалась как

$$f(t) = e^{-10(2\pi\{\frac{t}{2\pi}\} - \pi)^2} - \alpha,$$

где $\{\}$ – дробная часть числа, α – интеграл показателя степени по периоду для обнуления интеграла внешнего возмущения системы, $\alpha = 0.5605/2\pi$.

Для оценки уровня сложности механизмов регуляции, необходимых для ОДХ, на основе физиологических экспериментов были выбраны следующие значения параметров и начальные значения переменных: $w_1 = 2\pi * 0.86$, $w_2 = 2\pi * 1.1$ (соответствуют периодам цикла шага при однонаправленной ходьбе вперед и назад реальных кошек); $w = 2\pi * 5$ (соответствует периоду эпидуральной стимуляции); $x_0 = 0.9$, $y_0 = 0.91$, $x'_0 = y'_0 = 0$ (исходные положения обеих конечностей примерно совпадают; обе конечности неподвижны до включения стимуляции). На основе предварительных экспериментов было задано $\tau = 0.8$, $\varepsilon = 3$, $B = 10$.

Результаты и обсуждение

Результирующая колебательная активность при $\gamma = 3$ показана на рис. 1А. При этом наборе параметров модель может синхронизировать неравные частоты w_1 и w_2 , изначально присущие однонаправленной ходьбе вперед и назад, некоторой промежуточной частотой, подобной частоте ОДХ реальных кошек. Существование устойчивых синхронизированных колебаний зависит как от соотношения $|w_1/w_2|$, так и от параметра связности γ (рис. 1Г). При подаче внешнего воздействия (стимуляции) оба ЦГП начинают свои колебания из почти синфазного состояния, подобно поведению задних конечностей децеребрированной кошки [13]. Затем этот колебательный паттерн быстро переходит в стабильное противофазное состояние. Восходящие части кривых качественно могут быть связаны с фазой опоры шага; убывающие – с фазой переноса. Система (1) также имеет неустойчивый точечный аттрактор для синфазных решений при $w_1 = w_2$ и равных значениях начальных параметров (рис. 1В). Такая активность показана на рис. 1Б ($w_1 = w_2 = 2\pi$; $x_0 = 0.9$, $x'_0 = y'_0 = 0$). Подобная

картина синфазных колебаний может быть получена в системе (1), когда параметр связности γ отрицателен (рис. 1Г, $\gamma < 0$).




Рис. 1. Моделирование двусторонней активности при однонаправленной и двунаправленной ходьбе. А, Б: Моделирование колебательной активности двух ЦГП при разных начальных условиях. А: Противофазные колебания. Б: Синфазные колебания. В: Нестабильная точка аттрактора синфазных колебаний в параметрическом пространстве ($\gamma > 0$, условие равной частоты, $w_1 = w_2$). Г: Зависимость режима синхронизации от параметра связности γ (неодинаковые значения начальных параметров)

Комиссуральные взаимосвязи могут быть активными как во время фазы переноса (взаимные тормозящие взаимосвязи между сгибателями [14]), так и в течение всего локомоторного цикла (например, взаимные возбуждающие взаимосвязи между ипсилатеральными сгибателями и контралатеральными разгибателями). Данная модель поддерживает второй подход: функции взаимодействия действуют независимо от фазы цикла. В более сложных моделях могут использоваться разные параметры взаимодействия в зависимости от фазы цикла [15].

Сущность параметра связности γ в системе (1) аналогична сущности параметра A в моделях однонаправленной ходьбы вперед, учитывающих частоты связанных осцилляторов в первой степени [1, 2, 15]. Это значение

зависит от баланса активности некоторых типов возбуждающих и тормозных комиссуральных интернейронов в спинном мозге, как это было показано в экспериментах с генетически модифицированными животными [2, 16]. Преобладание возбуждающих взаимосвязей над тормозными переключает однонаправленную походку модели с ходьбы на галоп. На это значение также может влиять общая активация локомоторных сетей спинного мозга, например, за счет увеличения интенсивности супраспинального возбуждения или сенсорного входа. Первая возможность следует из [17]: характер однонаправленной ходьбы вперед может меняться от ходьбы к галопу при увеличении интенсивности электростимуляции мезэнцефалической локомоторной области. Вторая – из [18]: изменение скорости тредбана влияет на амплитуду мышечных пачек, т.е. $\gamma = \gamma(w)$. Одним из ограничений нашей простой модели является невозможность предсказать различную продолжительность фаз опоры и переноса для разных режимов ходьбы. Предположительно, за эту регуляцию отвечает следующий уровень многоуровневого ЦГП каждой задней конечности.

Интересно отметить, что в данной модели выключение тока (т.е. обнуление правой части системы (1)) не приводит к угасанию ритмической активности. Казалось бы, этот факт является существенным недостатком предложенной модели. Однако нами было показано, что однонаправленная ходьба вперед децеребрированного животного во время эпидуральной стимуляции может продолжаться длительное время и после выключения тока (пост-эффект) [11]. Таким образом, можно предположить, что параметр системы τ зависит от силы электрической стимуляции и, собственно, от факта ее наличия, т.е. $\tau = \tau(f(t))$; при отключении стимуляции τ меняет знак, что приводит к угасанию колебаний.

Выводы

Таким образом, на основе уравнений Ван-дер-Поля разработана нелинейная динамическая модель двух связанных ЦГП, способная генерировать ритм ходьбы, вызванной периодическим внешним возмущением. Получены численные значения параметров, при которых модель отражает особенности как однонаправленной, так и двунаправленной ходьбы. Найдены зависимости частот синхронизации от силы связи между ЦГП, а также точка неустойчивого равновесия системы. Результаты моделирования могут быть полезны для разработки схем новых биологических экспериментов по изучению локомоции.

Список литературы

1. Yuasa H., Ito M. Coordination of many oscillators and generation of locomotory patterns // *Biol. Cybern.* 1990. V. 63. P. 177–184.
2. Molkov Y.I., Bacak B.J., Talpalar A.E., Rybak I.A. Mechanisms of left-right coordination in mammalian locomotor pattern generation circuits: a mathematical modeling view // *PLOS Computational Biology*. 2015. V. 11. No 5. P. e1004270.
3. Kuwata N., Hoshi Y., Nohara B.T. Analysis of coupled van der Pol oscillators and implementation to a myriapod robot // *Proceedings of the 17th World Congress The International Federation of Automatic Control* Seoul, Korea, July 6–11, 2008. P. 767–772.
4. Jasni F., Shafie A.A. Van Der Pol central pattern generator (VDP-CPG) model for quadruped robot // *Trends in Intelligent, Robotics, Automation, and Manufacturing: First International Conference*, Kuala Lumpur, Malaysia, November 28–30, 2012. P. 167–175.
5. Lyakhovetskii V., Merkulyeva N., Gorskii O., Musienko, P. Simultaneous bidirectional hindlimb locomotion in decerebrate cats // *Sci. Rep.* 2021. V. 11. P. 3252.
6. Анищенко В.С., Астахов С.В., Вадивасова Т.Е., Феоктистов А.В. Численное и экспериментальное исследование внешней синхронизации двухчастотных колебаний // *Нелинейная динамика*. 2009. Т. 5, № 2. С. 237–252.
7. Egami C., Hirano N. Periodic solutions for forced Van der Pol type equations // *Proceedings of the ICM 2002 Satellite Conference on Nonlinear Functional Analysis*, Taiyuan, Shan Xi, PR China, 14–18 August 2002. P. 159–172.
8. Kitajama H., Noumi Y., Kousaka T., Kawakami H. Forced synchronization of coupled oscillators // *IEICE Trans. Fundamentals*. 1999. V. E82-A. N 4. P. 700–703.
9. Kuznetsov A., Turukina L., Chernyshov N., Sedova Yu. Synchronization of forced reactively coupled van der Pol oscillators // arxiv.org/abs/1502.03564. 2015.
10. Singh A.K., Yadava R.D.S. Synchronization and amplitude death in pair of van der Pol oscillators under conjugate coupling // *Phys. Scr.* 2019. V. 94. N 7. P. 075201.
11. Merkulyeva N., Lyakhovetskii V., Gorskii O., Musienko P. Differences in backward and forward treadmill locomotion in decerebrated cats // *J Exp Biol.* 2022. V. 225. N 9. P. jeb244210.
12. Богачева И.Н., Кучер В.И., Щербакова Н.А., Мусиенко П.Е., Герасименко Ю.П. Математическое моделирование процессов формирования локомоторных паттернов при эпидуральной стимуляции спинного мозга с учетом периферической обратной связи // *Биофизика*. 2005. Т. 50, № 6. С. 1125–1130.
13. Musienko P., Courtine G., Tibbs J.E., Kilimnik V., Savochin A., Garfinkel A., Roy R.R., Edgerton V.R., Gerasimenko Y. Somatosensory control of balance during locomotion in decerebrated cat // *J. Neurophysiol.* 2012. V. 107. P. 2072–2082.

14. Lam T., Pearson K.G. Proprioceptive modulation of hip flexor activity during the swing phase of locomotion in decerebrate cats // *J. Neurophysiol.* 2001. V. 86. P. 1321–1332.
15. Ito S., Yuasa H., Luo Z., Ito M., Yanagihara D. A mathematical model of adaptive behavior in quadruped locomotion // *Biol. Cybern.* 1998. V. 78. P. 337–347.
16. Kiehn O. Locomotor circuits in the mammalian spinal cord // *Annu Rev Neurosci.* 2006. V. 29. P. 279–306.
17. Шик М.Л., Северин Ф.В., Орловский Г.Н. Управление ходьбой и бегом посредством электрической стимуляции среднего мозга // *Биофизика.* 1966. Т. XI. № 4. С. 659–666.
18. Rossignol S. Neuronal control of stereotypic limb movements // In *Handbook of physiology* (eds. L.B. Rowell and J.T. Sheperd). 1996. P.173–216. Oxford University Press, New York.

В.И. МАЙОРОВ

Московский государственный университет им. М.В. Ломоносова
vimaigorov@mail.ru

***ABCD* НЕЙРОМОРФНОГО ИНТЕЛЛЕКТА**

Намечены элементы нейроморфного ядра интеллекта. Это *a)* “attractors” – аттракторные группы нейронов в рекуррентных нейронных сетях; *b)* “binding” – функциональные объединения групп на основе двунаправленной синаптической пластичности; *c)* “context/conditional” – образование обусловленных контекстом комбинаций и условных последовательностей; *d)* “dendrites” – локальная интеграция в дендритах, “dopamine” – модуляция связей дофамином, согласующаяся с дофаминовой теорией происхождения интеллекта.

Ключевые слова: *нейронные «аттракторы», дендриты, ассоциативная синаптическая пластичность, условные последовательности, контекст, дофамин.*

Введение

Несмотря на последние достижения в области искусственных нейронных сетей, многие считают, что по ряду параметров умственных способностей – языку, рассуждениям, здравому смыслу – искусственные нейронные сети не сравнимы с умственными способностями ребенка [1–10]. Может быть, одна из причин в том, что работы по искусственным нейронным сетям не принимают во внимание разрыв между разумом человека и интеллектом животных. «Великий водораздел – между высшими животными и человеком – был вызван... “творческой вспышкой” эволюции, которая... создала новый когнитивный аппарат» [11]. Здесь сделана попытка наметить некоторые элементы нейроморфного интеллекта, возможно, критические с точки зрения возникновения человеческого разума.

Attractors. Associations

Включение динамики аттракторов в современные системы глубокого обучения связано с трудностями: бассейны аттракторов характеризуются исчезающими градиентами (“vanishing gradient problem”), что делает обучение нейронных сетей методом градиентного спуска в принципе затруднительным [12]. С точки зрения вычислений само существование нейронных ансамблей (“assemblies”) некоторым кажется удивительным – «задача

нахождения плотного подграфа определенного размера в разреженном графе – известная трудная задача в информатике» (“the problem of finding a dense subgraph of a certain size in a sparse graph is a known difficult problem in computer science”) [13].

С другой стороны, для биологических рекуррентных нейронных сетей (RNN) функция автоассоциативной памяти – формирование «нейронных аттракторов» («ансамбли», “attractors”, “ensembles”, “assemblies”) – является естественной функцией, легко реализуемой в биофизических моделях.

Результаты нейронных исследований [14–16] и биофизического моделирования [17–20] свидетельствуют о том, что в результате обучения в рекуррентных нейронных сетях формируются дискретные аттракторные состояния. Внешние раздражители могут смещать нейронную активность к одному аттракторному состоянию или вызывать переход активности между несколькими дискретными состояниями [14–20].




Рис. 1. Схема рекуррентной нейронной сети с аттракторными группами A_1 - A_n , B_1 - B_n , C_1 - C_n ; D – дофаминовый нейрон – модулятор (по [19], с изменениями)

В биофизической модели рекуррентной нейронной сети, показанной на рис. 1 [19, 20], нейроны A_1 - A_n , B_1 - B_n , C_1 - C_n с более сильными (за счет обучения) внутригрупповыми связями образуют аттракторные группы, способные к спонтанному возбуждению при условии, что также в результате обучения они приобрели способность активировать дофаминовые нейроны D, модулирующие RNN. Связь с дофаминовыми нейронами здесь обеспечивает «самооблегчение» нейронной сети.

Примеры спонтанного возбуждения групп нейронов показаны на

рис. 2А, Б) Две аттракторные группы, значительно отличающиеся по силе связей с дофаминовыми нейронами (размер стрелок на рис. 1), тем не менее не отличаются по частоте спонтанных всплесков возбуждения. Избирательность возбуждения аттракторной группы создается минимальным (незаметным на рис. 2А, Б) влиянием контекста ϕ (рис. 1, рис. 2В), которое устанавливается путем обучения (например, усиление связей $\phi \rightarrow B_{1-n}$).




Рис. 2. А, Б – спонтанное возбуждение групп А (а) и В (b), n – номер нейрона, t – время, v – активность; В – частота возбуждения групп А (серые столбики) и В (светлые столбики) в соответствующем (+) и не соответствующем контексте; Г – изменение синаптического веса (w , по вертикали) при постоянном пресинаптическом возбуждении в зависимости от постсинаптического потенциала (v , по горизонтали); Д – возбуждение аттракторных групп А (а), В (b), С (c) в соответствующем каждой группе контексте (ϕ), при смене контекста сеть возвращается в исходное состояние; Е – динамика изменения синаптических весов (w , по вертикали) во время обучения (группы принудительно зажигаются несколько раз в случайном порядке – n , по горизонтали): 2 – веса связей от ядра группы к периферии, 3 – от периферии к ядру (1 – между нейронами внутри ядра и на периферии); Ж, 3 – разнонаправленные последовательности возбуждения восьми аттракторных групп в разном контексте (Ж: $\phi=2$, 3: $\phi=4$, по рис. 1). Величина возбуждения нейронов пропорциональна светлоте на рисунке (по [19, 20], с изменениями)

Нейронные «аттракторы» выглядят как естественная основа формирования «представлений», символов и ассоциаций. «Эндогенно активные состояния могут использоваться в качестве символов переменных в физическом мире, ... и, таким образом, позволяют ментальное манипулирование реальностью ... как “аттракторы”, состоящие из стабильных или полустабильных, повторяющихся паттернов активности, которые теоретически лежат в основе мыслей, восприятия и действий» [16].

Binding. Bidirectional plasticity

«Существующие нейронные сети не могут... эффективно формировать, представлять и связывать символические объекты, первопричина этой проблемы в неспособности существующих нейронных сетей динамически и гибко связывать (“binding”) информацию, распределённую в сети. Проблема связывания влияет на их способность формировать значимые сущности из неструктурированных сенсорных входов (сегрегация), чтобы поддерживать это разделение информации на репрезентативном уровне (представление) и использовать эти сущности для построения новых выводов, прогнозов и поведения (композиция)» [3].

Нейронные аттракторные группы на рис. 1 формируются и объединяются в последовательности (“binding”) на основе простого правила двусторонней синаптической пластичности (“bidirectional synaptic plasticity” – рис. 2Г). При активации выше некоторого порога и дофаминовой модуляции вес синапса увеличивается или уменьшается в зависимости от величины постсинаптического потенциала.

При применении к внутригрупповым связям это правило обеспечивает эффективное разделение пересекающихся аттракторных групп: внутригрупповые выходящие связи нейронов, которые не входят в другие группы (ядро аттрактора) со всеми нейронами группы, усиливаются (рис. 2Д-2, Е-2); нейроны, которые входят в несколько групп, теряют выходящие связи с нейронами ядра группы (рис. 2Д-3, Е-3).

Изменение межгрупповых связей лежит в основе формирования последовательностей (рис. 2Ж, 3) типа “replay/preplay” в гиппокампо-фронтальной системе [21] или последовательностей, представляющих “end points” отдельных движений в двигательной цепи [22–24]

Context. Conditional

В работе [20] показано, что при беспорядочном возбуждении аттракторных групп эффективность межгрупповых связей (при принятых правилах пластичности) стремится к нулю. Поэтому для понимания процессов в модели можно допустить, что внутренние межгрупповые синапсы (рис. 1. 1, 3, ...) в исходном состоянии до регулярного обучения являются функционально «молчащими» – имеют только NMDA-рецепторы и не изменяются. Внешние синапсы (рис. 1. 2, 4, ...) имеют только AMPA-рецепторы и характеризуются локальной ассоциативной (кооперативной) пластичностью – не имея собственных NMDA-рецепторов, они изменяются по тем же правилам, по каким изменялись бы соседние синапсы коллатеральных связей (1, 3, ...), будь у них AMPA-рецепторы. В результате,

образование и воспроизведение последовательностей становится зависимым от контекста (ϕ на рис. 1А). Последовательности возбуждения аттракторных групп становятся «условными последовательностями», обусловленными внешним (и/или внутренним) контекстом. Под влиянием внешнего по отношению к данной сети сигнала (контекста) генерируется та последовательность, которая вызывалась при обучении в том же контексте: последовательность ...BC... при $\phi \in 2$; противоположная последовательность ...CB... при $\phi \in 4$ (рис. 1, рис. 2Ж, 3).

Dendrites

Возможность формирования множества независимых условных последовательностей определяется наличием густоветвистого дендритного дерева с локальной интеграцией (ассоциацией) внешних и межгрупповых сигналов в отдельных дендритных ветвях [25]. Возможность локальной интеграции в дендритных ветвях в свою очередь зависит от сочетания многих факторов: от ассоциативной (кооперативной) пластичности, основанной на возбуждательном или тормозном (“dendritic gating”) взаимодействии синаптических входов [26], от Хеббовской пластичности – взаимодействия пресинаптической активности с постсинаптическим потенциалом, обусловленным обратным распространением в дендриты потенциала действия, генерируемого клеткой, от генерации дендритных спайков и их эффективного распространения к телу клетки [26–29] и от дофаминовой (наряду с другими) модуляции текущей (мгновенной) эффективности и долговременной пластичности связей [30–33].

Dopamine

Дофамин объединяет функции модуляции длительной синаптической пластичности и “мгновенной” эффективности (gating) связей, в частности, необходимой для инициации и поддержания движений [30–33]. Наряду с паркинсонизмом об этом, например, говорят данные об участии дофамина в речевом поведении. Люди с нарушением «речевого» гена FOXP2 демонстрируют нарушение речевого двигательного поведения, особенно способности производить или имитировать многосложные последовательности. Этот дефицит связан с ослабленной способностью производить быстрые последовательности движений. Исследования показали, что человеческая версия FOXP2 гена влияет на концентрацию дофамина, но не серотонина, GABA или глутамата, что приводит к увеличению длины дендритов и усиленной пластичности в стриатуме [33].

Dopamine and the origins of human intelligence (*Previc's Theory*)

Критическая роль дофаминовой модуляции в двух, на первый взгляд, не связанных друг с другом процессах – в сиюминутной регуляции эффективности синаптических связей (“gating”) и в индукции длительной синаптической пластичности (типа LTP) естественно согласуется (подтверждается и подтверждает) с дофаминовой теорией происхождения человеческого интеллекта [34–36], которая соединяет эволюцию человеческого интеллекта с экспансией дофаминовой системы головного мозга. Дофаминовая гипотеза эволюции человека подразумевает, что экспансия дофаминергической системы человека была самым важным фактором в изготовлении орудий, исследовании и культурном и научном развитии [36].

Теория Ф. Превика утверждает, что когнитивные способности, зависящие от дофамина, являются *экзаптацией* (“exaptation”) его функции терморегуляции – нейтрализации гипертермии, функции, которая отбиралась (“were positively selected”) для повышения физической выносливости (в особенности тепловой толерантности) во время продолжительной охоты в условиях жаркого климата юго-восточной Африки [34]. (Экзаптация – принцип эволюции органов путем смены функций. Пример экзаптации: оперение птиц, которое первоначально использовалось для регуляции температуры тела, в дальнейшем было адаптировано для полета). Можно было бы сказать, что аналогичным образом дофамин был адаптирован для «полета мысли», если бы терморегуляция изначально не входила как необходимый компонент в «двигательную» функцию дофамина.

Экспериментальные исследования, мотивированные гипотезой Превика, показали, что по сравнению с другими приматами мозг человека отличается увеличенной дофаминергической иннервацией вентрального и медулло-дорзального стриатума в области, ассоциированной с речью. Не было обнаружено отличий в иннервации префронтальной коры [37–39].

Заключение

А.М. Zador считает, что «если (в работах по созданию ИИ) нам когда-нибудь удастся достичь интеллекта хотя бы на уровне мыши, человеческий интеллект может оказаться лишь в небольшом шаге от нас» [1]. Но мы пока имеем очень слабое представление о содержании и заполнении того «бесконечного разрыва», который отделяет нас даже от обезьян.

В работе намечены некоторые элементы нейроморфного интеллекта, возможно, критические с точки зрения возникновения человеческого разума. Это ветвистые нейроны, группирующиеся в аттракторные группы,

нелинейная локальная интеграция в дендритах, основанная на двунаправленной синаптической пластичности, обусловленность связей контекстом и зависимость от дофаминовой модуляции, согласующаяся с дофаминовой теорией происхождения разума, которая соединяет эволюцию человеческого интеллекта с экспансией дофаминовой системы головного мозга.

Не только искусственные, но и биологические нейронные сети (в рамках биофизического моделирования) часто «по умолчанию» рассматриваются как состоящие из «точечных» (“point”) нейронов или нейронов, включающих всего несколько дендритных сегментов. Некоторые авторы [40–43] считают, что мозг правильнее сравнивать не с компьютером, а с интернетом (“a conception of the brain as a computing machine with the architecture of the internet” [43]), где роль компьютеров играют специализированные нейроны или небольшие группы нейронов типа концептуальных клеток [41, 42]. Рекуррентные сети, составленные из сложных ветвистых нейронов, в некоторой степени согласуются с этой метафорой.

Функциональный образ динамики комбинирования нейронных «аттракторов» в условные последовательности ассоциируется с образом динамики «атомов Эпикура» (во время бессознательного обдумывания задачи) из текста А. Пуанкаре: «Представим себе будущие элементы наших комбинаций чем-то вроде крючкообразных атомов Эпикура. Во время полного бездействия ума эти атомы неподвижны, как если бы они были повешены на стену; таким образом, этот полный покой ума может продолжаться неопределённо долго, и за всё это время атомы не сблизятся ни разу и, следовательно, не осуществится ни одна комбинация. В противоположность этому, в течение периода кажущегося покоя и бессознательной работы некоторые из атомов отделяются от стены и приходят в движение. Они бороздят по всем направлениям то пространство, в котором они заключены, подобно рою мошек или, если вы предпочитаете более учёное сравнение, подобно молекулам газа в кинетической теории газов. Тогда их взаимные столкновения могут привести к образованию новых комбинаций» [44].

Список литературы

1. Zador A.M. A critique of pure learning and what artificial neural networks can learn from animal brains // Nature Communication. 2019. 10:3770. P. 1–7.
2. Marcus G. The next decade in AI: Four steps towards robust artificial intelligence // CoRR, abs/1801.00631, 2020.
3. Greff K., van Steenkiste S., Schmidhuber J. On the Binding Problem in Artificial Neural Networks // arXiv:2012.05208v1 [cs.NE] 9 Dec 2020.

4. Garcez A., Lamb L.C. Neurosymbolic AI: The 3rd Wave // arXiv:2012.05876v2 [cs.AI] 16 Dec 2020.
5. Lample G., Charton F. Deep learning for symbolic mathematics // arXiv:1912.01412v1 [cs.SC] 2 Dec 2019.
6. Davis E. The Use of Deep Learning for Symbolic Integration A Review of (Lample and Charton, 2019) // arXiv:1912.05752v2 [cs.LG] 13 Dec 2019.
7. Hutson M. The language machines // Nature. 2021. V 591. P. 22–25.
8. Hasson U., Nastase S.A., Goldstein A. Direct Fit to Nature: An Evolutionary Perspective on Biological and Artificial Neural Networks // Neuron. 2020. V. 105. P. 416–434.
9. Sinz F.H., Pitkow X., Reimer J., Bethge M., Tolias A.S. Engineering a Less Artificial Intelligence // Neuron. 2019. V. 103. P. 967–979.
10. Ullman S. Using neuroscience to develop artificial intelligence // Science. 2019. V. 363, N 6428. P. 692–693.
11. Лоренц К. Кантовская концепция а priori в свете современной биологии // Эволюционная эпистемология. Москва ; Санкт-Петербург : Центр гуманитарных инициатив. 2012. С. 43–74.
12. Wu Y., Wayne G., Gregor K., Lillicrap T. Learning Attractor Dynamics for Generative Memory // arXiv:1811.09556v1 [cs.LG] 23 Nov 2018.
13. Papadimitriou C.H., Vempala S.S., Mitropolsky D., Collins M., Maass W. Brain computation by assemblies of neurons // PNAS. 2020. V. 117, N 25. P. 14464–14472.
14. Miller P. Itinerancy between attractor states in neural systems // Curr Opin Neurobiol. 2016. V. 40. P. 14–22. doi:10.1016/j.conb.2016.05.005
15. Yuste R. From the neuron doctrine to neural networks // Nat. Rev. Neurosci. 2015. V. 16. P. 487–497.
16. Carrillo-Reid L., Yuste R. Playing the piano with the cortex: role of neuronal ensembles and pattern completion in perception and behavior // Current Opinion in Neurobiology. 2020. V. 64. P. 89–95.
17. Rolls E.T. Attractor networks // Wiley Interdiscip Rev. Cogn. Sci. 2010. V. 1. P. 119–134.
18. Rolls E.T. The storage and recall of memories in the hippocampo-cortical system // Cell Tissue Res. 2018. V. 373, N 4. P. 577–604.
19. Майоров В.И. Модель нейронного механизма инструментализации движений, вызванных стимуляцией двигательной коры // Журнал высшей нервной деятельности им. И.П. Павлова. 2021. Т. 71, № 2. С. 202–212.
20. Майоров В.И. Модель формирования карты на основе ассоциации клеток направления и места // Журнал высшей нервной деятельности им. И.П. Павлова. 2021. Т. 71, № 5. С. 583–590.
21. Pfeiffer B.E., Foster D.J. Autoassociative dynamics in the generation of sequences of hippocampal place cells // Science. 2015. V. 349, N 6244.
22. Goudar V., Buonomano D.V. Encoding sensory and motor patterns as time-invariant trajectories in recurrent neural networks // eLife. 2018. 7:e31134.

23. Cone I., Shouval H.Z. Learning precise spatiotemporal sequences via biophysically realistic learning rules in a modular, spiking network // *eLife*. 2021. 10:e63751.
24. Miconi T. Biologically plausible learning in recurrent neural networks reproduces neural dynamics observed during cognitive tasks // 2017. *eLife*. 6:e20899.
25. Hawkins J., Ahmad S. Why neurons have thousands of synapses: a theory of sequence memory in neocortex // *Frontiers in Neural Circuits*. 2016. V. 10. Article 23. P. 1–13.
26. Sezener E. et al. A rapid and efficient learning rule for biological neural circuits // *bioRxiv preprint*. <https://doi.org/10.1101/2021.03.10.434756>
27. Poirazi P., Papoutsi A. Illuminating dendritic function with computational models // *Nature Rev. Neurosci.* 2020. V. 21, N 6. P. 303–321.
28. Stuart G.J., Spruston N. Dendritic integration: 60 years of progress // *Nature Neurosci.* 2015. V. 18, N. 12. P. 1713–1721.
29. Li S., Liu N., Zhang X., McLaughlin D.W., Zhou D., Cai D. Dendritic computations captured by an effective point neuron model // *PNAS*. 2019. V. 116, N 30. P. 15244–15252.
30. Klaus A., da Silva J.A., Costa R.M. What, If, and When to Move: Basal Ganglia Circuits and Self-Paced Action Initiation // *Annu. Rev. Neurosci.* 2019. V. 42. P. 459–83.
31. Hughes R.N., Bakhurin K.I., Petter E.A., Watson G.D.R., Kim N., Friedman A.D., Yin H.H. Ventral tegmental dopamine neurons control the impulse vector during motivated behavior // *Curr Biol*. 2020. V. 30, N 14. P. 2681–2694.
32. Yagishita S., Hayashi-Takagi A., Ellis-Davies G.S.R., Urakubo H., Ishii S., Kasai H. A critical time window for dopamine actions on the structural plasticity of dendritic spines // *Science*. 2014. V. 345, N 6204. P. 1616–1620.
33. Alm P.A. The Dopamine System and Automatization of Movement Sequences: A Review with Relevance for Speech and Stuttering // *Front. Hum. Neurosci.* 2021. 15: 661880.
34. Previc, F. H. Dopamine and the origins of human intelligence // *Brain and Cognition*. 1999. V. 41. P. 259–299.
35. Saniotis A., Grantham J.P., Kumaratilake J., Henneberg M. Neuro-hormonal Regulation Is a Better Indicator of Human Cognitive Abilities Than Brain Anatomy: The Need for a New Paradigm // *Front. Neuroanat.* 2020. V. 13. Article 101. P. 1–11.
36. Hoffmann M. The Human Frontal Lobes and Frontal Network Systems: An Evolutionary, Clinical, and Treatment Perspective // *ISRN Neurology*. V. 2013. Article ID 892459. 34 p.
37. Raghanti M.A., Stimpson C.D., Marcinkiewicz J.L., Erwin J.M., Hof P.R., Sherwood C.C. Cortical dopaminergic innervation among humans, chimpanzees, and macaque monkeys: A comparative study // *Neuroscience*. 2008. V. 155, N 1. P. 203–220.
38. Raghanti M.A., Edler M.K., Stephenson A.R., Wilson L.J., Hopkins W.D., Ely J.J., Erwin J.M., Jacobs B., Hof P.R., Sherwood C.C. Human-specific increase of dopaminergic innervation in a striatal region associated with speech and language: a comparative analysis of the primate basal ganglia // *J Comp Neurol*. 2016. V. 524,

N 10. P. 2117–2129

39. Hirter K., Miller E.N., Stimpson C.D., Phillips K.A., Hopkins W.D., Hof P.R., Sherwood C.C., Lovejoy C.O., M.A. The Nucleus Accumbens and Ventral Pallidum Exhibit Greater Dopaminergic Innervation in Humans Compared to Other Primates // *Brain Struct. Funct.* 2021. V. 226, N 6. P. 1909–1923.
40. Аршавский Ю.И., Делягина Т.Г., Орловский Г.Н. Центральные генераторы: механизмы работы и их роль в управлении автоматизированными движениями // *Журнал высшей нервной деятельности им. И.П. Павлова.* 2015. Т. 65, № 2. С. 156–187.
41. Аршавский Ю.И. Память: аксиоматика и факты // *Журнал высшей нервной деятельности им. И.П. Павлова.* 2021. Т. 71, № 2. С. 184–201.
42. Manin D.Yu., Manin Yu.I. Cognitive networks: brains, internet, and civilizations // *arXiv:1709.03114v1 [cs.AI]* 10 Sep 2017.
43. Langille J.J., Gallistel C.R. Locating the engram: Should we look for plastic synapses or informationstoring molecules? // *Neurobiology of Learning and Memory.* 2020. V. 169. P. 1–15.
44. Пуанкаре А. О науке. Москва : Наука, 1983.

В.И. МАЙОРОВ

Московский государственный университет им. М.В. Ломоносова
vimaigorov@mail.ru

ФУНКЦИИ ДОФАМИНА В ОБУЧЕНИИ С ПОДКРЕПЛЕНИЕМ

Последние экспериментальные данные опровергают гипотезу о дофаминовом сигнале как переносчике “reward prediction error” (RPE). «Дофаминовый драйв» является движущей силой того побудительного значения, которое цель действия приобретает путем Павловской ассоциации с поощрением или наказанием. Дофаминовый сигнал в одно и то же время активизирует двигательную систему поведения и создает необходимые условия для индукции пластических перестроек в синапсах (“synaptic tag”), которые «подкрепляются» при условии редукции дофаминового драйва.

Ключевые слова: *условный рефлекс, подкрепление, мотивация привлекательностью, дофамин, ошибка предсказания, целенаправленные действия, привычки.*

Введение

«Обучение через подкрепление» – ключевой алгоритм бихевиоризма: «идентичность, приписываемая личности, создаётся факторами подкрепления, ответственными за её поведение» [1]. Точка зрения на подкрепление как на исключительный фактор формирования поведения животных и человека была подвергнута жесткой критике, например, К. Лоренцом, Н. Хомски, Н.А. Бернштейном. «Ортодоксальные приверженцы этого учения (бихевиоризма) заявляют, что человек рождается подобным чистому листу бумаги, а все, что он думает, чувствует, знает и во что он верит, является результатом «кондиционирования» [2]. «Почти непостижимо, как люди вообще решаются с готовностью твердить, будто подкрепление условного рефлекса неотъемлемо важно для обучения – если всерьез числить подкрепление чем-то, что возможно распознать и определить независимо от наступающих перемен в поведении» [3].

Но «бихевиоризм жив» [4]. Т. Сейновски объявил «Дело против А.Н. Хомского» [5]. “Reward is enough... intelligence, and its associated abilities, can be understood as subserving the maximisation of reward by an agent acting in its environment... it suggests that a good reward-maximising agent, in

the service of achieving its goal, could implicitly yield abilities associated with intelligence” [6].

Если “reward is enough”, почему оказались безуспешными все попытки научить языку обезьян?

Обучение с подкреплением: условный рефлекс

«Термин “подкрепление”... употребляется в разном смысле в системе Павлова и в системе Халла... Используя этот термин, следует помнить, что он имеет операционный характер и сам по себе несколько не помогает выяснению физиологических механизмов описываемых явлений. Если рассматривать классический условный рефлекс просто как частный случай ассоциации, то можно прийти к выводу, что термин “подкрепление” является лишним. В самом деле, выражение “условный рефлекс подкрепляется безусловным агентом” равноценно выражению “безусловный агент (US) следует сразу же за условным сигналом (CS)”, а “подкрепляющий раздражитель” есть не что иное, как раздражитель, активирующий принимающие нейроны» [7].

Хотя и неизвестно, необходимо ли дополнительное (дофаминовое) «подкрепление» для выработки классического Павловского условного рефлекса (УР) ($CS \rightarrow US$), оно необходимо для выработки ассоциации между «индифферентными» раздражителями ($CS1 \rightarrow CS2$), например парами слов. Способность человека к созданию ассоциаций практически неограниченна [8]. После *однократного* предъявления списка, состоящего из 500 (1000) словесных пар, испытуемые запоминали около 99% (95%) пар, воспроизводя второе слово в паре при предъявлении первого. Необходимым условием запоминания, которое сообщали испытуемым, было *«установить для каждой пары какую-нибудь смешную или нелепую ассоциацию с первым словом в списке»* [8].

Необходимость третьего фактора (дофамина) для запоминания ассоциаций также следует из результатов опытов на животных на клеточном уровне [9, 10].

Негативное подкрепление. Условный рефлекс избегания

Под негативным подкреплением в бихевиоризме понимается прекращение (избавление – escape) или избегание (avoidance) авersiveного состояния в результате действия животного (негативное подкрепление – не наказание). *Что является внутренним фактором негативного подкрепления с точки зрения “reward is enough”* – сигнал безопасности (“safety signal”) в результате перехода из неприятного ($v < 0$) в нейтральное ($v = 0$)

состояние: $[(v = 0) - (v < 0)] > 0$, или каким-то образом сам факт избавления от аверсивного состояния («редукция драйва»)?

«Физиология активности». Подтверждение против подкрепления

«Текущие теоретические и вычислительные модели обучения с подкреплением (RL) в значительной степени уходят корнями в классическую бихевиористскую традицию, делая упор на обучение по принципу «стимул–реакция» (S-R), и представляют организм как чисто *реактивного* получателя вознаграждений и наказаний, с результирующим поведением, которое по существу отражает сумму этой истории подкрепления» [4].

«Необходимо подчеркнуть решающее принципиальное различие между... намечаемыми *физиологией активности* проявлениями экстраполяционного поиска и путем, описывавшимся бихевиористами под названием “проб и ошибок”. Под последними понимается последовательность попыток, каждая из которых не обусловлена предыдущими и в одинаковой с ними мере производится наудачу... накопление же опыта трактуется, по сути, как чисто пассивный статистический учет удач и неудач... Неслучайно этот принцип так легко имитируется в машинных моделях.

В отличие от него тот активный “нелокальный поиск”, который, видимо, является действительным орудием ориентировочного поведения, после первой же пары попыток, случайных или приближенно направленных элементарными градиентными механизмами, заключает по ним, как и куда должен быть сделан очередной шаг. Каждая проба уточняет таким путем оптимальное направление, по которому может быть добыта наибольшая и самая ценная информация» [11].

Концепция подкрепления не была важной переменной научения для Е.С. Толмена, хотя и наблюдается некоторое сходство между тем, что Толмен называл *подтверждением*, и тем, что другие бихевиористы именovali подкреплением. В процессе формирования когнитивной карты организм использует ожидания. *Ожидания* – это предвидение последствий того или иного шага, которые либо подтверждаются опытом, либо нет. Гипотезы, оправдавшие себя, сохраняются, а те, что не нашли подтверждения, отбрасываются. Так формируются когнитивные карты [12].

Подтверждение ожидания в формировании когнитивной карты имеет сходство с понятием подкрепления как «редукции драйва», используемым другими бихевиористами, но противоположно пониманию подкрепления как ошибки предсказания вознаграждения в RL.

Целенаправленные действия и привычки

Оперантные (инструментальные) реакции разделяют на действия, выполняемые *в расчете* на получение вознаграждения (goal-directed), и привычки (habits), выполняемые *без оглядки* на возможный результат [13–15]. Первые, будучи выработанными, перестают выполняться после насыщения или образования пищевой аверсии. Вторые в тех же условиях продолжают выполняться. Инструментальный УР вначале вырабатывается как целенаправленное действие, а потом становится привычкой. Выработка целенаправленного поведения основана на формировании привлекательности цели («мотивация привлекательностью», “*incentive motivation*”). В результате цель действия – рычаг или место в лабиринте или финальная поза многосуставного движения, приобретает привлекательность и притягивает животное. Приобретение привлекательности (“*incentive salience attribution*” [12, 16]) «мыслится в соответствии с классической схемой образования условно-рефлекторных связей по Павлову, а не с инструментальным научением по Торндайку» [12, 16].

Обучение с подкреплением: ИИ

Началось как союз идей математической психологии и искусственного интеллекта с сопутствующими трудностями прямой имплементации понятий в нейронные сети [17]. “*RL requires exploration, as the learner is responsible for discovering actions that increase reward*” [18]. Говорят о model-free (MF) и model-based (MB) формах RL. В то время как RL без моделей (MF) является стандартной формой S-R-O (Стимул–Реакция–Результат), подходы, основанные на моделях (MB), используют внутреннюю модель среды, чтобы предвидеть потенциальные результаты последовательности действий, делая выбор действий на основе этих перспективных прогнозов [4, 19, 20].

В основе MF лежит локальный механизм обучения в зависимости от “temporal difference (TD) prediction error” – вероятность действия, выполняемого из данного состояния, изменяется в соответствии с *изменением* (“temporal difference”) величины (“value”) ожидания вознаграждения или наказания после выполнения действия и перехода в другое состояние (“prediction error”). MF-животное обучается и выбирает действие «на территории» в соответствии с установленными для данного положения / состояния вероятностями. MB-животное (пере)оценивает значения (“value”) точек на карте и выбирает план действий «по карте» (модели), опираясь на представления о дальних последствиях своих действий, получаемых, например, с помощью механизмов типа “preplay” в гиппокампо-

фронтальной системе [21]. RL ожидаемо должно происходить в последовательности $MF \rightarrow MB$ – иначе как могла бы сформироваться когнитивная карта (модель территории), по которой прокладывается путь к цели.

Дихотомия между *model-based* (MB) и *model-free* (MF) RL рядом авторов понимается как синоним дихотомии между целенаправленными действиями и привычками в инструментальном УР [20].

Действительно, в случае MB обучения / поведения естественно представить механизм присваивания ценности (“valuation”) цели (месту на карте) как Павловский ассоциативный механизм. Но надо иметь в виду, что а) дихотомия между целенаправленными действиями и привычками имеет *определенное содержание* только в рамках схемы экспериментов А. Dickinson, В. Balleine с соавторами [13, 14]; б) целенаправленное действие преобразуется в привычку в противоположность последовательности $MF \rightarrow MB$ (о других различиях в [20]). *Что в таком случае с точки зрения RL служит подкреплением при выработке привычки в условиях полной предсказуемости вознаграждения?* (Отражение этого вопроса можно увидеть в названии одной из работ – “Habits without value” [22]); в) с точки зрения физиологии активности, обучающим сигналом (подкреплением) при формировании карты является подтверждение, а не ошибка ожидания (RPE).

По замечанию О’Reilly [4]: «...MB-животное (отыскивает цель на карте, используя внутреннюю модель среды) методом «что – если», уступая большей части человеческого опыта, тогда как архитектура познания, фактически реализованная в нашем мозгу, фундаментально структурирована в соответствии с целями, которые *существуют с самого начала*...».

RPE и дофамин

Алгоритм TD RL оказал значительное влияние на понимание функции дофамина (DA) в мозге. На основании того, что в *определённых экспериментах* паттерны фазового возбуждения дофаминовых нейронов в вентральной тегментальной области (VTA) отражают характеристики ошибки прогнозирования вознаграждения, сигнал DA стали рассматривать как универсальный обучающий сигнал [23–25].

Странно, что в качестве иллюстрации функции дофамина в RL, где обучающийся ответственен за действия, ведущие к получению вознаграждения («*as the learner is responsible for discovering actions that increase reward*» [18]), обычно, начиная с [23], приводятся данные об активности дофаминовых нейронов во время выработки классического Павловского УР [23, 26] (рис. 1А), хотя, как уже отмечалось, понятие «подкрепление»

употребляется в разном смысле: в классическом Павловском и инструментальном УР. Что с точки зрения «дофаминовой версии» RL служит подкреплением при выработке привычки в отсутствие ошибки ожидания вознаграждения?




Рис. 1. А. Активность дофаминового нейрона VTA при выработке Павловского ассоциативного рефлекса. CS – условный сигнал (УС), Rw – вознаграждение (по [23], с изменениями). На всех рисунках по горизонтали время в секундах. Б. Динамика дофаминового сигнала (voltammetry data) при выполнении крысой инструментального УР (нажатие на рычаг), черные треугольники – начало поступления молока из поилки, стандартная скорость поступления молока 0.2 мл/30 с, кривые сверху вниз показывают динамику дофаминового сигнала при подаче молока в отдельных случаях со скоростью 0, 0.1, 0.2, 0.4, 0.6 мл/30 с (по [27], с изменениями). В. Динамика дофаминового сигнала в зависимости от числа нажатий на рычаг (от 1 до 10 сверху вниз), необходимых для включения поилки (0.2 мл/30 с) (по [27], с изменениями). Г. Возбуждение дофаминового нейрона (1) перед началом исследовательской двигательной активности (2) в открытом поле (по [28], с изменениями). Д. Активность нейрона VTA при выработке УР избегания. Сверху вниз номера испытаний, серые кружки – включение УС, треугольник – реакция избегания или удар током, если избегание не происходит в течение 10 с после включения УС. При всех избеганиях, начиная с самого первого (указано стрелкой), возбуждение нейрона (спайки – вертикальные черные метки) предшествует реакции избегания, звездочками отмечены пробы с избеганиями, кривая – средняя частота активности нейрона при всех избеганиях (по [29], с изменениями). Е, Ж. Пунктирная линия – средняя частота нажатий на рычаг, необходимых для получения пищевого вознаграждения, сплошная – величина слюноотделения в ответ на включение классического УС (треугольник), сигнализирующего подачу пищи (по [7], с изменениями)

«Дофаминовая версия» теории обучения с подкреплением не обращает внимания на необходимость активации дофаминовой системы для инициации и выполнения движений, на что указывает, в первую очередь, опыт паркинсонизма и многочисленные экспериментальные данные (рис. 1Б–Д) [27–31]. Авторы работы с характерным названием «Ventral tegmental dopamine neurons control the impulse vector during motivated behavior» делают заключение: «Our findings... are inconsistent with the popular RPE hypothesis of DA function» [30]. Авторы работы с не менее характерным названием «Reward prediction error does not explain movement selectivity in DMS-projecting dopamine neurons» приходят к аналогичному выводу: “We have ruled out the possibility that the activity (DA signal) is actually a single RPE for action value” [31].

Связывание выброса дофамина с подкреплением возвращает к известному с середины прошлого века «drive–reward» парадоксу [32]: «Выяснение того факта, что мотивация (инициация движений) и подкрепление вызываются одной и той же стимуляцией, в свое время вызвало шок в психологии, эхо которого слышно и поныне» [33, 34]. С тех пор, как стало понятно, что в обоих случаях речь идет об активности дофаминовых нейронов среднего мозга, сосуществуют две почти не пересекающиеся гипотезы о дофамине как о медиаторе мотивации и подкрепления [32].

Условное подкрепление. “Shaping” (“Clicker-training”)

Примером одного из самых эффективных алгоритмов оперантного обучения является “shaping” (“clicker-training”) – обучение с использованием условного подкрепления [35]. Здесь последовательность действий (траектория движений) разбивается на мелкие части, при правильном выполнении каждой из которых животное *немедленно* получает *подтверждающий* правильность действия условный сигнал (“click”), а вслед за тем подкрепление (вознаграждение). *Что является физиологическим фактором условного подкрепления при обучении этим методом?*

Ю. Конорски с сотрудниками показали, что включение УС Павловского пищевого условного рефлекса, вызывающего слюноотделение, сразу же подавляет инструментальные двигательные реакции, необходимые для получения пищевого вознаграждения (рис. 1Е–Ж) [7]. Близкие по смыслу результаты были позднее получены в работе [36]. Эти данные могут указывать на одновременное торможение активности дофаминовых нейронов.

Р. Dayan [37], используя результаты и терминологию, введенную К. Berridge [33], высказал гипотезу, что подкрепляющим фактором в про-

цессе “shaping” является “liking” в качестве предвкушения. Но в многочисленных работах последнего не только отрицается связь “liking” с дофаминовым сигналом, но и связь дофаминового сигнала с подкреплением [33, 38].

Заключение

Результаты последних [30, 31], как, впрочем, и самых первых [27] работ, опровергают гипотезу о дофаминовом сигнале как переносчике RPE. Результаты большого числа экспериментальных работ о функциях дофамина в поведении можно объединить и схематически представить таким образом [39]. Оперантное обучение начинается с того, что цель действия путем Павловской ассоциации с поощрением или наказанием становится привлекательной или отталкивающей, приобретает побудительное значение (“*incentive salience attribution*”) [12, 16], движущей силой которого является «дофаминовый драйв». Отдельный механизм для «склеивания» (“glue”) [40] связей на основе подкрепления (или дофаминовой модуляции) на этой стадии, может быть, и не нужен [7, 12, 37].

Дофаминовый сигнал совмещает в одном временном окне функцию активации двигательной системы (инициации движения) [27–31] и создает необходимые условия для индукции пластических перестроек в синапсах (“synaptic tag”) [10], которые «подкрепляются» при условии редукции дофаминового драйва сразу же после достижения целевого состояния нейронной активности (при подкреплении).

Список литературы

1. Skinner B.F. Beyond freedom and dignity. 1971. Скиннер Б.Ф. Превыше свободы и чести // <https://coollib.com/b/459981-bf-skinner-prevyishe-svobodyi-i-chesti/readp>
2. Лоренц К. Восемь смертных грехов цивилизованного человечества // Так называемое зло. Москва : Культурная революция. 2008. С. 7–83.
3. Chomsky N. A Review of BF Skinner's Verbal Behavior // Language. 1959. V. 35, N 1. P. 26–58.
4. O'Reilly R.C., Hazy T.E., Mollick J., Mackie P., Herd S. Goal-Driven Cognition in the Brain: A Computational Framework // arXiv:1404.7591v1 [q-bio.NC] 30 Apr. 2014.
5. Сейновски Т. Дело против А.Н. Хомского // Антология машинного обучения. 2022. Москва : Изд-во «Бомбора». С. 268–273.
6. Silver D., Singh S., Precup D., Sutton R.S. Reward is enough // Artificial Intelligence. 2021. V. 299. P. 1–13.
7. Конорски Ю. Интегративная деятельность мозга // Москва : Мир. 1970.

8. Миллер Дж., Галантер Ю., Прибрам К. Планы и структуры поведения. Москва : Изд-во «Прогресс». 1965.
9. Sharpe M.J., Chang C.Y., Liu M.A., Batchelor H.M., Mueller L.E., Jones J.L., Niv Y., Schoenbaum G. Dopamine transients are sufficient and necessary for acquisition of model-based associations // *Nat Neurosci.* 2017. V. 20, N 5. P. 735–742.
10. Yagishita S., Hayashi-Takagi A., Ellis-Davies G.S.R., Urakubo H., Ishii S., Kasai H. A critical time window for dopamine actions on the structural plasticity of dendritic spines // *Science.* 2014. V. 345, N 6204. P. 1616–1620.
11. Бернштейн Н.А. Физиология движений и активность. Москва : Наука, 1990.
12. Хекхаузен Х. Мотивация и деятельность // 2003. Глава 6. Волевые процессы: реализация интенций. СПб. : «Питер». Москва : «Смысл», 2003.
13. De Wit S., Dickinson A. Associative theories of goal-directed behavior: A case for animal-human translational models // *Psychological Research.* 2009. V. 73, N 4. P. 463–476.
14. Balleine B.W. The Meaning of Behavior: Discriminating Reflex and Volition in the Brain // *Neuron.* 2019. V. 104. P. 47–62.
15. Yin H.H., Knowlton B.J. The role of the basal ganglia in habit formation // *Nat. Rev. Neurosci.* 2006. V. 7, N 6 P. 464–476.
16. Bolles R.C. Reinforcement, expectancy, and learning // *Psychological Review.* 1972. V. 79, N 5. P. 394–409.
17. Dayan P. Reinforcement Learning // Pashler H., Gallistel R. (Eds.) *Steven's handbook of experimental psychology: Learning, motivation and emotion.* 2002. P. 103–129. John Wiley & Sons Inc.
18. Botvinick M., Wang J.X., Dabney W., Miller K.J., Kurth-Nelson Z. Deep Reinforcement Learning and Its Neuroscientific Implications // *Neuron.* 2020. V. 107. P. 603–616.
19. Dayan P., Berridge K.C. Model-based and model-free Pavlovian reward learning: Revaluation, revision, and revelation // *Cogn. Affect Behav. Neurosci.* 2014. V. 14, N 2. P. 473–492.
20. Collins A.G.E., Cockburn J. Beyond dichotomies in reinforcement learning // *Nature Reviews Neuroscience.* 2020. V. 21, N 10. P. 576–586.
21. Pfeiffer B.E., Foster D.J. Hippocampal place-cell sequences depict future paths to remembered goals // *Nature.* 2013. V. 497, N 7447. P. 74–79.
22. Miller K.J., Shenhav A., Ludvig E.A. Habits without values // *Psychol Rev.* 2019. V. 126, N 2. P. 292–311.
23. Montague P.R., Dayan P., Sejnowski T.J. A framework for mesencephalic dopamine systems based on predictive Hebbian Learning // *J. Neurosci.* 1996. V. 16, N 5. P. 1936–1947.
24. Diederer K.M.J., Fletcher P.C. Dopamine, Prediction Error and Beyond // *The Neuroscientist.* 2021. V. 27, N 1. P. 30–46
25. Starkweather C.K., Uchida N. Dopamine signals as temporal difference errors: recent advances // *Current Opinion in Neurobiology.* 2021. V. 67. P. 95–105.
26. Н.Ю. Ивлиева. Роль стриатума в двигательном научении // *Журнал высшей нервной деятельности им. И.П. Павлова.* 2022. Т. 72, № 2. С. 159–186.

27. Richardson N.R., Gratton A. Behavior-Relevant Changes in Nucleus Accumbens Dopamine Transmission Elicited by Food Reinforcement: An Electrochemical Study in Rat // *J. of Neurosci.* 1996. V. 16, N 24. P. 8160–8169.
28. Klaus A., da Silva J.A., Costa R.M. What, If, and When to Move: Basal Ganglia Circuits and Self-Paced Action Initiation // *Annu. Rev. Neurosci.* 2019. V. 42. P. 459–83
29. Майоров В.И., Серков А.Н. Активность нейронов вентральной тегментальной области среднего мозга при первом выполнении условного рефлекса активного избегания // *Журнал высшей нервной деятельности им. И.П. Павлова.* 2016. Т. 66. № 6. С. 725–729.
30. Hughes R.N., Bakhurin K.I., Petter E.A., Watson G.D.R., Kim N., Friedman A.D., Yin H.H. Ventral tegmental dopamine neurons control the impulse vector during motivated behavior // *Curr Biol.* 2020. V. 30, N 14. P. 2681–2694.
31. Lee R.S., Mattar M.G., Parker N.F., Witten I.B., Daw N.D. Reward prediction error does not explain movement selectivity in DMS-projecting dopamine neurons // *eLife.* 2019. 8:e42992. <https://doi.org/10.7554/eLife.42992>
32. Wise R.A. Dual roles of dopamine in food and drug seeking: the drive-reward paradox // *Biol. Psychiatry.* 2013. V. 73, N 9. P. 819–826.
33. Berridge K.C., Robinson T.E. What is the role of dopamine in reward: Hedonic impact, reward learning, or incentive salience // *Brain Research Reviews.* 1998. V. 28, N 3. P. 309–369.
34. Morgane P.J. Medial forebrain bundle and “feeding centers” of the hypothalamus // *J. Comp. Neurol.* 1961. V. 117, N 1. P. 1–25.
35. Прайор К. Не рычите на собаку! // М.: «Эксмо». 2014.
36. Crombag H.S., Galarce E.M., Holland P.C. Pavlovian influences on goal-directed behavior in mice: The role of cue-reinforcer relations // *Learn. Mem.* 2008. V. 15. P. 299–303. doi:[10.1101/lm.762508](https://doi.org/10.1101/lm.762508)
37. Dayan P. “Liking” as an early and editable draft of long-run affective value // *PLoS Biol.* 2022. 20(1): e3001476.
38. Robinson S., Sandstrom S.M., Denenberg V.H., Palmiter R.D. Distinguishing Whether Dopamine Regulates Liking, Wanting, and/or Learning About Rewards // *Behav. Neurosci.* 2005. V. 119, N 1. P. 5–15.
39. Майоров В.И. Функции дофамина в инструментальном условном рефлексе // *Журнал высшей нервной деятельности им. И.П. Павлова.* 2018. Т. 68, № 4. С. 404–414.
40. Walker E.L. Reinforcement – The one ring // In J.T. Trapp (Ed.), *Reinforcement and behavior* (P. 47–62). New-York: Academic Press. 1969.

И.А. НАЖЕСТКИН

Московский физико-технический институт
(национальный исследовательский университет)
nazhestkin@phystech.edu

**ПРИБЛИЖЁННЫЕ МЕТОДЫ ВЫЧИСЛЕНИЯ
КОЭФФИЦИЕНТА ИНТЕГРИРОВАННОЙ ИНФОРМАЦИИ
ДЛЯ ИССЛЕДОВАНИЯ ПЛАСТИЧНОСТИ НЕЙРОННЫХ
СЕТЕЙ ГОЛОВНОГО МОЗГА ПРИ ОБУЧЕНИИ***

Коэффициент интегрированной информации Φ является перспективной метрикой, оценивающей степень адаптации головного мозга к окружающей среде. Однако его вычисление значительно затруднено. В настоящей работе исследовались три метода приближённого вычисления Φ на данных нейронной активности гиппокампа крыс, выполняющих многодневное оперантное обучение пищедобывающему навыку. Было показано, что Φ , вычисленный с помощью всех трёх методов, успешно предсказывает степень успешности выполнения навыка.

Ключевые слова: *теория интегрированной информации, нейрон, обучение, гиппокамп.*

Введение

Теория интегрированной информации и её основное понятие – *коэффициент интегрированной информации* Φ – первоначально были предложены и успешно применены для оценки уровня сознания в головном мозге человека [1–7] и в нервной системе более простых организмов [8]. В то же время было показано, что коэффициент Φ хорошо описывает производительность других сложных систем, состоящих из некоторого количества взаимодействующих элементов [9–11]. Φ показывает уровень сложности системы, возникающий из локального обмена информацией между взаимодействующими компонентами, образующими связи путём самоорганизации [12]. Было показано на вычислительной модели, что Φ отражает переход между внутренними состояниями сложной системы [13]. В вычислительной модели головного мозга, обучающейся по правилу Хэбба, Φ , вычисленный на смоделированной ЭЭГ, увеличивался с ходом

* Исследование выполнено при финансовой поддержке РФФИ в рамках научного проекта № 20-34-90023.

обучения и показал взаимосвязь с количеством аттракторов в сети [14]. Φ , вычисленный на основе ЭЭГ новорождённых детей, увеличивался с их возрастом и, следовательно, с ходом развития мозга [15]. Таким образом, применение коэффициента интегрированной информации для анализа самоорганизации нейронов в головном мозге представляет собой перспективную задачу.

Коэффициент Φ оценивает две способности сложной системы, критически важные для её работы, – сегрегацию информации и её интеграцию. *Сегрегация* означает, что система должна иметь возможность находиться в как можно большем числе состояний, чтобы закодировать как можно большее количество различных стимулов. При этом важно, чтобы компоненты системы были сильно специализированы, то есть были связаны с кодированием, например, только одного вида стимулов. *Интеграция* заключается в том, что такие компоненты системы должны быть взаимосвязаны между собой. Это критически важно для работы системы как единого целого. Малые значения Φ указывают на то, что в системе имеется место со слабой взаимосвязью компонентов, что отрицательно сказывается на её производительности.

Для практического вычисления коэффициента интегрированной информации используется так называемый алгоритм авторегрессионного Φ [16]:

$$\Phi_{AR} = \frac{\min_M \left[\frac{1}{2} \ln \frac{\det \Sigma(X)}{\det \Sigma(E^X)} - \sum_k \frac{1}{2} \ln \frac{\det \Sigma(M_k)}{\det \Sigma(E^{M_k})} \right]}{\frac{1}{2} \ln \left[\min_k ((2\pi e)^{|M_k|} \det \Sigma(M_k)) \right]}, \quad (1)$$

где $\Sigma(X)$ – ковариационная матрица для переменной X , E^X – остатки (ошибки предсказания) линейной регрессии, предсказывающей значение переменной X в момент времени $t + \Delta t$ на основании значения X в момент времени t , M_k – подвыборки системы (разбиение её на две части), $|X|$ – мощность множества X . Непосредственное вычисление по определению не применяется на практике, поскольку требует нормального распределения входных данных, и получаемый результат неустойчив при объёмах, получаемых при большинстве экспериментов. Подвыборки выбираются наиболее независимыми, то есть таковыми, что разбиение системы на них даст минимальное значение Φ_{AR} . Таким образом, оценивается наиболее слабое место системы, в котором имеется недостаток связей между элементами, что приводит к увеличению средних путей передачи информации и, таким образом, к снижению производительности системы.

Однако вычисление Φ на практических данных нейронной активности невозможно вследствие значительной вычислительной сложности алгоритма. Требуется перебрать все возможные разбиения системы на части, и количество вариантов для системы из N элементов описывается числом Белла B_N , которое растёт быстрее экспоненты [17]. В оригинальной работе [16] предлагается для упрощения рассматривать только разбиения на 2 части, однако и такая задача сохраняет значительную вычислительную сложность. Поэтому для практического вычисления Φ необходимы приближённые алгоритмы. В настоящей работе рассматриваются три приближённых алгоритма: один с полным перебором разбиений на 2 части на ограниченном наборе нейронов, и два с приближённо определённым разбиением на полном наборе.

Постановка поведенческого эксперимента

В работе были использованы открытые данные [18-20]. Крысы линии Long-Evans ($n = 3$) были обучены сложному навыку ориентирования в W-образном лабиринте. Перед обучением животным в область CA1 правого гиппокампа имплантировались микроэлектроды. В течение 5–7 дней после операции животным был предоставлен реабилитационный период, после чего начиналось обучение. Для получения вознаграждения животным необходимо было пробежать от конца одного рукава к концу другого по определённым правилам, описанным в оригинальной статье [18]. Каждый день проводилась одна или две экспериментальные сессии продолжительностью 15–20 минут. Во время каждой сессии было зарегистрировано от 15 до 56 нейронов.

Вычисление коэффициента интегрированной информации и статистический анализ

Коэффициент интегрированной информации Φ вычислялся по алгоритму авторегрессионного Φ для данных нейронной активности в каждой сессии. Кроме того, каждая сессия была разбита на 8 равных периодов, и Φ был вычислен в каждом из этих периодов. В каждом из периодов также вычислялось число успешных актов (количество вознаграждений, выданных животным). Поскольку экспериментальные сессии имели разную длину, количество вознаграждений нормировалось на длину периода. Между Φ и относительным количеством вознаграждений вычислялся коэффициент корреляции Спирмена, а нулевая гипотеза об отсутствии корреляции проверялась с использованием критерия Стьюдента. При статистическом анализе применялась поправка Бонферрони на множественные

сравнения с количеством гипотез $N=15$ и минимальным уровнем значимости $\alpha = 0.05/15 = 0.0034$.

Для вычисления Φ системы необходимо указать, что является узлами и определить состояния узлов в каждый момент времени. В данном случае узлами являются нейроны, а состояния узлов определяются следующим образом. Время разбивается на отрезки (бины) равного размера. В случае если в бине i нейрон произвёл спайк, то считается, что в момент времени i узел (нейрон) имел состояние 1, а если спайка не было, то считается, что узел имел состояние 0.

В некоторых случаях Φ_{AR} найти не удавалось. Такое поведение происходит, когда узлы сети меняют свою активность слишком редко, и регрессии, фигурирующие в (1), не могут быть вычислены. В данном случае это происходило, когда нейрон был почти всегда не активен, или, наоборот, активировался почти в каждом бине. В таком случае заново отбиралось на единицу меньшее число нейронов и вычисление повторялось. После вычисления полученное значение Φ_{AR} нормировалось на количество нейронов, фактически участвовавших в расчёте. Это было сделано для обеспечения возможности сравнения результатов, полученных на различном числе нейронов.

Выбор размера бина осуществляется на основе компромисса между сохранением тонких паттернов спайковой активности нейронов и избыточными данными. При слишком большом размере бина будет потеряно много тонких паттернов активности нейрона; кроме того, практически все бины будут иметь состояние 1 (в силу размера в них, как правило, попадёт хотя бы один нейрон), и алгоритм не сможет найти Φ_{AR} вследствие невозможности нахождения авторегрессий в (1). При слишком малом размере бина значительно увеличится время расчётов, а также возможна и неудача в вычислении Φ_{AR} (по аналогичной причине, но здесь почти все бины будут в состоянии 0). В данном исследовании был выбран размер бина 0.03 с.

Одним из параметров является сдвиг по количеству временных шагов Δt . Коэффициент Φ по определению показывает разность в информации, генерируемой системой за некоторое количество шагов (последовательных состояний). Имеются все основания полагать, что в головном мозге обработка информации происходит периодически [21–23], и длина этого периода по разным оценкам варьируется от 50 до 500 мс [15]. Как и в [10], при вычислениях использовалось такое значение Δt , которое приводило к максимальному среднему значению Φ_{AR} .

Вычисления и построения графиков проводились в среде MATLAB. Для непосредственного вычисления коэффициента интегрированной информации Φ_{AR} использовался модифицированный открытый код из [16]. Статистический анализ выполнялся в программе GraphPad Prism.

Алгоритмы приближённого вычисления параметра интегрированной информации

Наиболее очевидным упрощением является сокращение количества используемых нейронов. Подобный подход применялся (не для головного мозга) в [10]. На современном ПК (процессор AMD Ryzen 7 4800H 2.9 GHz, 16 GB 3.2 GHz DDR4 RAM) при переборе разбиений на 2 части (как предложено в [16]) удалось достичь предела в 15 нейронов. Отбор нейронов осуществлялся по тому же принципу, что и удаление нейронов, делающих невозможным вычисления: отбирались 15 нейронов с наибольшей дисперсией распределения Бернулли. В различных сессиях было зарегистрировано от 15 до 56 нейронов, поэтому потеря информации в данном приближении составляла от 0 до 73%.

Избежать исключения нейронов и, следовательно, потерь информации позволяет другой класс приближённых методов, при которых искомое разбиение системы, минимизирующее Φ , заменяется другим, легко определяемым, но частично сохраняющим свойства исходного. Грубым приближением является так называемое *атомарное разбиение*, при котором каждый нейрон включается в свою подвыборку, состоящую только из него самого. Это даёт значительный прирост в скорости вычисления, однако такое разбиение не отражает реальную структуру головного мозга, ответственную за обработку информации.

Для наиболее совершенного класса алгоритмов используется информация об анатомической структуре нейронных сетей головного мозга. Известно, что нейроны образуют тесные кластеры с большой плотностью связей внутри них. Эти кластеры соединяются друг с другом при помощи нейронов, имеющих большое число связей во всём мозге (так называемого «клуба избранных»). При этом тесные сообщества выполняют высокоспециализированную обработку определённой информации, а связи между ними отвечают за её интеграцию [24, 25]. Таким образом, видно, что нахождение подобной структуры практически точно соответствует исходной задаче нахождения разбиения. Синаптическая структура определяется путём расчёта корреляций между последовательностями спайковой активности нейронов. Далее применяются различные алгоритмы нахождения тесных сообществ в графе [26]. В настоящей работе для подобных

целей был использован алгоритм Ловена [27], который основан на минимизации модулярности – специальной метрики, которая показывает относительную плотность связей внутри сообществ.

Результаты

Все животные успешно выработали требуемый навык.

Коэффициент интегрированной информации Φ был вычислен для нейронной активности гиппокампа всех трёх животных с использованием трёх приближённых методов. Результаты для каждого дня обучения и для каждого вычислительного метода показаны на рис. 1. Оптимальные значения характерного временного масштаба Δt для всех случаев представлены в табл. 1. Видно, что полученные результаты (порядка 0.3–0.5 с) соответствуют указанным в [15].

Таблица 1

**Характерный временной масштаб обработки информации
для трёх животных**

	<i>15 нейронов</i>	<i>Разбиение Ловена</i>	<i>Атомарное разбиение</i>
<i>Животное 1</i>	14 бинов (0.42 с)	15 бинов (0.45 с)	15 бинов (0.45 с)
<i>Животное 2</i>	16 бинов (0.48 с)	17 бинов (0.56 с)	13 бинов (0.39 с)
<i>Животное 3</i>	13 бинов (0.39 с)	12 бинов (0.36 с)	12 бинов (0.36 с)




Рис. 1. Значение коэффициента интегрированной информации Φ для каждого животного во все дни обучения, вычисленное с использованием трёх различных методов

Значения, полученные с помощью различных методов, имели отличия в амплитуде в некоторых точках, однако в целом временной тренд сохранялся. Значения, полученные методами, использующими полный набор нейронов, были значительно больше по амплитуде, несмотря на нормировку на количество нейронов. Это легко объяснимо, поскольку при удалении части нейронов происходит потеря информации.

Для первого и третьего животных была обнаружена статистически значимая корреляция между относительным количеством вознаграждений и значением Φ . Для нейронной активности третьего животного корреляция была обнаружена только для метода с использованием 15 нейронов (табл. 2).

Таблица 2

Взаимосвязь относительного количества вознаграждений и параметра интегрированной информации Φ для нейронной активности гиппокампа, вычисленного тремя различными методами¹

	15 нейронов	Разбиение Ловена	Атомарное разбиение
Животное 1	$r = 0.4796$ $p < 0.0001$ **	$r = 0.5364$ $p < 0.0001$ **	$r = 0.5911$ $p < 0.0001$ **
Животное 2	$r = 0.3229$ $p = 0.0008$ *	$r = -0.2274$ $p = 0.0213$ ns	$r = -0.1293$ $p = 0.3987$ ns
Животное 3	$r = 0.3096$ $p = 0.0014$ *	$r = 0.5726$ $p < 0.0001$ **	$r = 0.6544$ $p < 0.0001$ **

¹ Указан коэффициент корреляции Спирмена, вероятность нулевой гипотезы и уровень статистической значимости. Учтена поправка Бонферрони для 15 проверяемых гипотез.

У второго животного было зарегистрировано наибольшее число нейронов (до 56), поэтому была выдвинута гипотеза о том, что дополнительные нейроны, которые были включены в анализ, но были исключены в 15-нейронном приближении, не участвуют в формировании навыка и их Φ не имеет взаимосвязи с выполнением задачи. Поэтому коэффициент Φ был рассчитан с помощью метода с разбиением Ловена и с атомарным разбиением в тех же условиях, но на ограниченном наборе в 15 нейронов. В результате статистически значимая корреляция была обнаружена для всех животных (табл. 3). В таблице указаны коэффициент корреляции

Спирмена, вероятность нулевой гипотезы и уровень статистической значимости, учтена поправка Бонферрони для 15 проверяемых гипотез.

Таблица 3

Взаимосвязь относительного количества вознаграждений и параметра интегрированной информации Φ для нейронной активности гиппокампа, вычисленного приближёнными методами на ограниченном наборе из 15 нейронов

	Разбиение Ловена	Атомарное разбиение
Животное 1	$r = 0.6767$ $p < 0.0001$ **	$r = 0.6645$ $p < 0.0001$ **
Животное 2	$r = 0.4557$ $p < 0.0001$ **	$r = 0.3952$ $p < 0.0001$ **
Животное 3	$r = 0.6060$ $p < 0.0001$ **	$r = 0.6544$ $p < 0.0001$ **

Выводы

Была исследована возможность применения коэффициента интегрированной информации Φ к оценке степени адаптации головного мозга к условиям среды. Для практического применения подобного подхода были рассмотрены три приближённых метода, позволяющих с высокой степенью точности вычислить Φ для спайковых данных нейронной активности за небольшое время. Было показано, что все три метода успешно выполняют поставленную задачу, и коэффициент Φ , вычисленный с помощью каждого метода, показывает степень адаптации мозга к среде.

Список литературы

1. Tononi G., Edelman G.M., Sporns O. Complexity and coherency: integrating information in the brain // Trends in cognitive sciences. 1998. V. 2, N 12. P. 474–484.
2. Tononi G. An information integration theory of consciousness // BMC neuroscience. 2004. V. 5, N 1. P. 1–22.
3. Balduzzi D., Tononi G. Integrated information in discrete dynamical systems: motivation and theoretical framework // PLoS computational biology. 2008. V. 4, N 6. P. e1000091.

4. Tononi G. The integrated information theory of consciousness: an updated account // Archives italiennes de biologie. 2012. V. 150, N 2/3. P. 56–90.
5. Sarasso S. [et al.]. Consciousness and complexity during unresponsiveness induced by propofol, xenon, and ketamine // Current Biology. 2015. V. 25, N 23. P. 3099–3105.
6. Casali A.G. [et al.]. A theoretically based index of consciousness independent of sensory processing and behavior // Science translational medicine. 2013. V. 5, N 198. P. 198ra105.
7. Lee U.C. [et al.]. Propofol induction reduces the capacity for neural information integration: implications for the mechanism of consciousness and general anesthesia // Nature Precedings. 2008. P. 1–30.
8. Leung A. [et al.]. Integrated information structure collapses with anesthetic loss of conscious arousal in *Drosophila melanogaster* // PLoS computational biology. 2021. T. 17, N 2. P. e1008722.
9. Edlund J.A. [et al.]. Integrated information increases with fitness in the evolution of animats // PLoS computational biology. 2011. V. 7, N 10. P. e1002236.
10. Engel D., Malone T.W. Integrated information as a metric for group interaction // PloS one. 2018. V. 13, N 10. P. e0205335.
11. Niizato T. [et al.]. Finding continuity and discontinuity in fish schools via integrated information theory // PloS one. 2020. V. 15, N 2. P. e0229573.
12. Mediano P.A. M. [et al.]. Integrated information as a common signature of dynamical and information-processing complexity // Chaos: An Interdisciplinary Journal of Nonlinear Science. 2022. V. 32, N 1. P. 013115.
13. Popiel N.J.M. [et al.]. The emergence of integrated information, complexity, and ‘consciousness’ at criticality // Entropy. 2020. V. 22, N 3. P. 339.
14. Fujii K., Kanazawa H., Kuniyoshi Y. Spike Timing Dependent Plasticity Enhances Integrated Information at the EEG Level: A Large-scale Brain Simulation Experiment // 2019 Joint IEEE 9th International Conference on Development and Learning and Epigenetic Robotics (ICDL-EpiRob). IEEE, 2019. P. 137–142.
15. Isler J.R. [et al.]. Integrated information in the EEG of preterm infants increases with family nurture intervention, age, and conscious state // PloS One. 2018. V. 13, N 10. P. e0206237.
16. Barrett A.B., Seth A.K. Practical measures of integrated information for time-series data // PLoS computational biology. 2011. V. 7, N 1. P. e1001052.
17. Rota G.C. The number of partitions of a set // The American Mathematical Monthly. 1964. V. 71, N 5. P. 498–504.
18. Jadhav S.P. [et al.]. Coordinated excitation and inhibition of prefrontal ensembles during awake hippocampal sharp-wave ripple events // Neuron. 2016. V. 90, N 1. P. 113–127.
19. Tang W. [et al.]. Hippocampal-prefrontal reactivation during learning is stronger in awake compared with sleep states // Journal of Neuroscience. 2017. V. 37, N 49. P. 11789–11805.
20. Jadhav, S.P.; Frank, L. Simultaneous Extracellular Recordings from Hippocampal Area CA1 and Medial Prefrontal Cortex from Rats Performing a W-Track Alterna-

- tion Task; CRCNS.org; 2020. <https://doi.org/10.6080/K02N50G9>.
21. VanRullen R. Perceptual cycles // *Trends in cognitive sciences*. 2016. V. 20, N 10. P. 723–735.
 22. Fiebelkorn I.C., Pinsk M.A., Kastner S. A dynamic interplay within the frontoparietal network underlies rhythmic spatial attention // *Neuron*. 2018. V. 99, N 4. P. 842–853. e8.
 23. Helfrich R.F. [et al.]. Neural mechanisms of sustained attention are rhythmic // *Neuron*. 2018. V. 99, N 4. P. 854–865. e5.
 24. Li Y. [et al.]. Brain anatomical network and intelligence // *PLoS computational biology*. 2009. V. 5, N 5. P. e1000395.
 25. Park H.J., Friston K. Structural and functional brain networks: from connections to cognition // *Science*. 2013. V. 342, N 6158. P. 1238411.
 26. Toker D., Sommer F.T. Information integration in large brain networks // *PLoS computational biology*. 2019. V. 15, N 2. P. e1006807.
 27. Blondel V.D. [et al.]. Fast unfolding of communities in large networks // *Journal of statistical mechanics: theory and experiment*. 2008. V. 2008, N 10. P. P10008.

В.Е. ТИТОВ, О.Е. ДИК

Санкт-Петербургский государственный университет аэрокосмического
приборостроения
titovvadim82@gmail.com

ЧАСТОТНЫЙ АНАЛИЗ НА ОСНОВЕ СИНХРОСЖАТОГО ВЕЙВЛЕТ-ПРЕОБРАЗОВАНИЯ РИТМОВ МОЗГА И СЕРДЦА ПРИ СОСУДИСТОЙ ПАТОЛОГИИ МОЗГА*

Рассматривается применение синхросжатого вейвлет-преобразования для оценки связи между ритмами мозга и сердца при сосудистой патологии различной степени тяжести до и во время гипервентиляционной нагрузки. Выявленные особенности частотных взаимосвязей ритмов мозга и сердца во время гипервентиляционной нагрузки могут быть полезны при поиске нейрофизиологических коррелят степени тяжести сосудистой патологии головного мозга.

Ключевые слова: *электроэнцефалограмма, вариабельность сердечного ритма, синхросжатое вейвлет-преобразование.*

Введение

При диагностике нарушений функционального состояния мозга, связанного с сосудистой патологией, обычно применяют анализ биоэлектрической активности мозга в виде электроэнцефаллограммы (ЭЭГ).

Сосудистая патология мозга связана с медленно прогрессирующей недостаточностью кровоснабжения головного мозга, приводящей к нарастающим диффузным структурным изменениям и нарушениям когнитивных функций мозга [1, 2].

При анализе таких изменений в ЭЭГ используют функциональную нагрузку в виде гипервентиляционной пробы, так как считается, что в случае сосудистой патологии мозга форсированное дыхание может провоцировать возможную транзиторную ишемию [3]. В то же время из-за вариабельности возможного ответа мозга на гипервентиляционную пробу как в норме, так и при патологии, интерпретация результатов может быть неоднозначной [4]. В этих случаях дополнительную информацию клиницистам может дать одновременный анализ биоэлектрической активности

* Данная работа выполнена при финансовой поддержке Министерства науки и высшего образования Российской Федерации, соглашение № FSRF-2020-0004.

мозга и сердца в виде ЭЭГ и электрокардиограммы (ЭКГ) с последующим анализом динамики частот.

Различие в частотных диапазонах ЭЭГ и ЭКГ приводит к необходимости использовать предварительное выделение единого диапазона в этих сигналах. При этом нестационарность ЭЭГ и ЭКГ приводит к тому, что применять спектральный Фурье анализ не совсем верно. Вместо этого правильнее использовать метод расчета мгновенных частот на основе вейвлет-преобразования сигнала [5, 6]. Этот метод широко используется для выявления синхронизации между ритмами сердечно-сосудистой и дыхательной систем [7–12]. В работах [13, 14] показано значение оценки степени синхронизации для изучения функционального состояния вегетативной регуляции кровообращения для лиц с сердечно-сосудистыми заболеваниями, оценки персонального сердечно-сосудистого риска и оптимизации медикаментозной терапии.

В отличие от ритмов сердечно-сосудистой и дыхательной систем, биоэлектрическая активность мозга, регистрируемая с поверхности головы в виде ЭЭГ, как правило, сильно зашумлена. Для повышения эффективности извлечения мгновенной частоты и фазы из экспериментальных данных с высоким уровнем шума лучше применять метод синхросжатого вейвлет-преобразования [15]. В работах [16, 17] этот метод применен для выявления мгновенных фаз и частот для последующего анализа фазовой синхронизации между ритмической фотостимуляцией мозга и откликом на нее в виде ЭЭГ, и получены данные, позволяющие различать параметры синхронизации у двух групп лиц с хронически повышенным артериальным давлением, имеющих и не имеющих умеренные нарушения когнитивных функций. Показано, что эти нарушения коррелируют с большей длительностью фазовой синхронизации и сдвигом ответов мозга в более низкочастотный диапазон, по сравнению с частотой возбуждения [16, 17].

Целью данной работы является применение синхросжатого вейвлет-преобразования для оценки отношения мгновенных частот в низкочастотных составляющих ЭЭГ (в дельта диапазоне) и временной последовательности интервалов времени между двумя последовательными R-пиками, извлеченных из ЭКГ паттернов у пациентов с сосудистой патологией различной степени тяжести до и во время гипервентиляционной нагрузки.

Экспериментальные данные и методы их анализа

Проанализированы записи ЭЭГ и ЭКГ 15 женщин в возрасте от 56 до 65 лет с сосудистой патологией, ассоциированной с вегето-сосудистой

дистонией (группа I) и связанной с вертебрально-базиллярной недостаточностью, развившейся в результате шейного остеохондроза (II группа). Данные предоставлены Санкт-Петербургской неврологической клиникой, исследование одобрено местным комитетом по этике.

Сигналы ЭЭГ и ЭКГ записывались одновременно в состоянии покоя и при воздействии функциональной нагрузки (гипервентиляции). Длительность каждой записи составляла 6 минут. С каждым испытуемым было проведено по три измерения в разные дни. Частота дискретизации равна 512 Гц.Arteфакты были предварительно удалены врачом-нейрофизиологом. Для анализа ЭЭГ были использованы данные в затылочных долях мозга (O1-, O2- и O2-отведениях), где биоэлектрическая активность мозга была наиболее выражена во всех записях. Для анализа частот дельта диапазона исходные записи ЭЭГ отфильтровывали с полосой пропускания 0,04–0,45 Гц.

Для извлечения из сигнала ЭКГ последовательности RR интервалов, то есть интервалов времени между двумя последовательными R пиками, мы использовали вейвлет-преобразование с базисным вейвлетом sym4 , по форме напоминающим QRS-комплекс [18]. Затем неэквилидистантная последовательность RR интервалов аппроксимировалась кубическими сплайнами и подвергалась дискретизации с частотой 256 Гц. Полученная эквидистантная последовательность определяет так называемую *вариабельность сердечного ритма* (BCP).

Для оценки отношения мгновенных частот паттернов ЭЭГ в дельта диапазоне и в последовательности BCP мы применили метод синхросжато-го вейвлет-преобразования [15].

В данной работе в качестве вейвлетной функции мы использовали обычно применяемый для непрерывного вейвлет-преобразования сигнала вейвлет Морле, который при значении параметра вейвлета $\omega_0 = 2\pi f_0, f_0 = 1$, обеспечивает простую связь между масштабом a вейвлет-преобразования и реальной частотой f анализируемого сигнала:

$$f = \left(\left(\omega_0 + \sqrt{2 + \omega_0^2} \right) / 4\pi a \right) \approx \frac{1}{a}. \quad (1)$$

Непрерывное вейвлет-преобразование (CWT – continuous wavelet transform) сигнала $s(t)$ для вейвлетной функции $\psi(t)$ определяется формулой:

$$W_s(a, b) = \frac{1}{a} \int_{-\infty}^{+\infty} s(t) \bar{\psi}\left(\frac{t-b}{a}\right) dt, \quad (2)$$

где a и b – переменные масштаба и временного сдвига, $\bar{\psi}((t-b)/a)$ – вейвлетная функция, полученная из материнского вейвлета $\psi(t)$ путем масштабирования и сдвига по времени, символ означает комплексное сопряжение [8].

Синхросжатое вейвлет-преобразование (SWT – syncrosqueezed wavelet transform) сигнала $s(t)$ задается следующим образом [15]:

$$T_s(\omega_l, b) = \frac{1}{\Delta\omega} \sum_{a_k} W_s(a_k, b) a_k^{-\frac{3}{2}} \Delta a_k, \quad a_k: |\omega(a_k, b) - \omega_l| \leq \Delta\omega/2, \quad (3)$$

где ω_l – l -й дискретная круговая частота, a_k – k -й – дискретный масштаб и $\Delta a_k = a_k - a_{k-1}$.

Время (Δt_{cor}) возникновения корреляции мгновенных частот диапазона сверхмедленных ритмов ЭЭГ и ВСР определялось как интервал времени, в течение которого после начала гипервентиляционной пробы устанавливалось следующее соотношение:

$$0.95 \leq f_{\text{ЭГ}} / f_{\text{ВСР}} \leq 1.05. \quad (4)$$

Для сравнения средних значений Δt_{cor} , полученных для разных групп испытуемых, применялся однофакторный дисперсионный анализ ANOVA. Статистически значимые отличия между группами определялись на основании значений $p < 0.05$ в силу того, что число групп $k = 2$, $n = k(k-1)/2 = 1$, $1 - 0.951/n = 0.05$.

Результаты

Для обеих групп пациентов с сосудистой патологией в паттернах ЭЭГ для дальнейшего анализа мы выделили низкочастотный дельта-ритм в диапазоне частот от 0,04 до 0,45 Гц. В связи с тем, что для всех испытуемых не было обнаружено достоверных различий для правого и левого отведений O_1 и O_2 , в настоящей работе будут представлены результаты, полученные только для центрального отведения O_z .

Рисунок 1 демонстрирует пример отсутствия взаимосвязей между мгновенными частотами дельта-диапазона ЭЭГ и ВСР. Этот пример получен для пациента А с сосудистой патологией из группы I до гипервентиляционной пробы. Проекция вейвлетной поверхности $(t, f, |Ws(f, t)|^2)$ на плоскость (t, f) , полученная методом SWT для ЭЭГ (рис. 1а), имеет полосы частот, не совпадающие с полосой на проекции вейвлетной поверхности для ВСР (рис. 1б). Усредненные по времени распределения энергии ESW(f) синхросжатых вейвлетных спектров ЭЭГ и ВСР по частотам имеют максимумы на частотах 0,34 Гц и 0,12 Гц для ЭЭГ и для ВСР соответственно (рис. 1в, г). Извлеченные из SWT гребни показаны на рис. 1д. Вычисленное на основании этих гребней отношение мгновенных частот $f_{\text{ЭГ}} / f_{\text{ВСР}}$ превышает значение 2 (рис. 1е).




Рис. 1. Результаты, полученные до гипервентиляции для пациента А из группы I

Рисунок 2 показывает, что, в отличие от отсутствия взаимосвязей между мгновенными частотами дельта-диапазона в фоновой ЭЭГ и ВСР для пациента А, во время гипервентиляционной нагрузки между мгновенными частотами ЭЭГ и ВСР возникают корреляции.

Проекции вейвлетных поверхностей $(t, f, |Ws(f, t)|^2)$ на плоскость (t, f) для ЭЭГ и для ВСР имеют полосы, совпадающие вблизи частоты 0.4 Гц (рис. 2а, б). Усредненные по времени распределения энергии $ESW(f)$ синхросжатых вейвлетных спектров имеют хорошо выраженные максимумы на частотах 0,39, 0,46 и 0,51 Гц для ЭЭГ и 0,39 Гц для ВСР соответственно (рис. 2в, г). Выделенные из спектров SWT гребни максимально приближаются друг к другу на частоте 0,39 Гц спустя 55 с после начала гипервентиляции (рис. 2д). Таким образом, временной интервал, в течение которого отношение мгновенных частот $f_{ЭЭГ}/f_{ВСР}$ становится равным 1 ± 0.05 (рис. 2е), составляет 55 с. Итак, для пациента А время возникновения корреляции между мгновенными частотами дельта-диапазона ЭЭГ и ВСР во время гипервентиляционной нагрузки $\Delta t_{кор} = 55$ с.




Рис. 2. Результаты, полученные после гипервентиляции для пациента А из группы I

Для пациента Б из группы II также характерно наличие взаимосвязей между мгновенными частотами дельта-диапазона ЭЭГ и ВСП во время гипервентиляционной нагрузки (рис. 3). Совпадение полос в проекциях вейвлетных поверхностей $(t, f, |W_s(f, t)|^2)$ на плоскость (t, f) для ЭЭГ и для ВСП происходит вблизи частоты 0.28 Гц (рис. 3а, б). Усредненные по времени распределения энергии $E_{SW}(f)$ синхросжатых вейвлетных спектров для ЭЭГ и ВСП имеют хорошо выраженные максимумы на частоте 0,28 Гц (рис. 3в, г). Выделенные из спектров SWT гребни максимально приближаются друг к другу на этой частоте 0,28 Гц спустя 42 с после начала гипервентиляции (рис. 3д). Таким образом, для пациента Б, время возникновения корреляции между мгновенными частотами дельта-диапазона ЭЭГ и ВСП во время гипервентиляционной нагрузки меньше, чем для пациента А, и составляет $\Delta t_{\text{cor}} = 42$ с (рис. 3е).




Рис. 3. Результаты, полученные после гипервентиляции для пациента Б из группы II

Средние значения мгновенных частот паттернов ЭЭГ и ВСП до и во время гипервентиляции для обеих анализируемых групп представлены в табл. 1.

Данные табл. 1 указывают на отсутствие корреляции между мгновенными частотами низкочастотного дельта-диапазона фоновых паттернов ЭЭГ и ВСП для обеих групп. Средние значения $f_{\text{ЭЭГ}}$ до гипервентиляции равны 0.29 ± 0.05 Гц для пациентов из группы I и 0.35 ± 0.05 Гц для пациентов из группы II. Средние значения $f_{\text{ВСП}}$ до гипервентиляции меньше и равны 0.12 ± 0.03 Гц для пациентов из группы I и 0.18 ± 0.04 Гц для пациентов из группы II.

Таблица 1

Средние значения мгновенных частот ЭЭГ и ВСР до и во время гипервентиляции для разных групп

Пациенты	$f_{\text{ЭЭГ}}$ (Гц)	$f_{\text{ВСР}}$ (Гц)
до гипервентиляции		
группа I ($N = 8/8$)	$0,29 \pm 0,05$	$0,12 \pm 0,03$
группа II ($N = 7/7$)	$0,35 \pm 0,05$	$0,18 \pm 0,04$
во время гипервентиляции		
группа I ($N = 8/8$)	$0,43 \pm 0,07$	$0,38 \pm 0,06$
группа II ($N = 7/7$)	$0,31 \pm 0,05$	$0,23 \pm 0,04$

Во время гипервентиляции средние значения $f_{\text{ЭЭГ}}$ увеличивались и равны $0,43 \pm 0,07$ Гц для пациентов из группы I и $0,31 \pm 0,05$ Гц для пациентов из группы II. Средние значения $f_{\text{ВСР}}$ также повышались и равны соответственно $0,38 \pm 0,06$ Гц для пациентов из группы I и $0,23 \pm 0,04$ Гц для пациентов из группы II.

Результаты однофакторного дисперсионного анализа для сравнения средних значений величин Δt_{cor} для разных групп испытуемых представлены на рис. 4. Этот рис. 4 демонстрирует различие в средних временах возникновения корреляции между мгновенными частотами дельта-диапазона ЭЭГ и ВСР во время гипервентиляционной нагрузки.




Рис. 4. Результаты однофакторного дисперсионного анализа для сравнения средних значений величин Δt_{cor} для группы I и группы II

Большие различия в центральных линиях (медианах выборочных значений Δt_{cor}) свидетельствуют о значительных различиях в групповых средних. Статистика, полученная по F-критерию Фишера $F = 27,35$, превышает критическое значение $F_{\text{crit}} = F_{1,12} = 4,7$. Уровень значимости критерия Фишера, т.е. максимальная вероятность ошибочно отклонить нулевую гипотезу о равенстве средних, когда она верна, близок к нулю

($p = 0,0002$). Следовательно, примененный тест ANOVA показал достоверные различия между средними значениями величин Δt_{cor} для пациентов из двух тестируемых групп.

Таким образом, наблюдаемая для обеих анализируемых групп корреляция между мгновенными частотами дельта-диапазона ЭЭГ и паттернами ВСП при гипервентиляционной нагрузке статистически значимо отличается по времени появления такой корреляции. Среднее значение Δt_{cor} ниже у пациентов с сосудистой патологией, ассоциированной с вертебрально-базилярной недостаточностью ($\Delta t_{\text{cor}} = 34,3 \pm 8,0$, II группа), по сравнению со средним значением $\Delta t_{\text{cor}} = 56,4 \pm 8,1$, полученным для пациентов с меньшей степенью тяжести сосудистой патологии, связанной с вегетососудистой дистонией (группа I).

Заключение

Анализ мгновенных частот в низкочастотных составляющих ЭЭГ и временной последовательности RR интервалов, извлеченных из ЭКГ, проведенный до и после гипервентиляционной нагрузки для двух групп испытуемых с сосудистой патологией разной степени тяжести, показал, что уменьшение времени появления корреляции между мгновенными частотами диапазона сверхмедленных ритмов ЭЭГ и ВСП связано со степенью сосудистой патологии головного мозга. Чем больше выраженность сосудистой патологии мозга, тем быстрее возникает корреляция между мгновенными частотами диапазона сверхмедленных ритмов ЭЭГ и вариабельности сердечного ритма.

Список литературы

1. Tadic M., Cuspidi C., Hering D. Hypertension and cognitive dysfunction in elderly: blood pressure management for this global burden // BMC Cardiovasc Disorders. 2016. V. 16. P. 208–217.
2. Gasecki D., Kwarciany M., Nyka W., Narkiewicz K. Hypertension, brain damage and cognitive decline // Current Hypertension Reports. 2013. V. 15, N 6. P. 547–558.
3. Gnezditsky V.V., Koshurnikova E.E., Korepina O.S., [et al.]. Space-time and dipole analysis of hyperventilation-induced EEG changes: interpretation problems // Functional diagnostics. 2010. V. 2, N 1. P. 1–18.
4. Goldenson E.S., Legatt A.D., Koszer S. [et al.]. EEG interpretation: problems of overreading and underreading. Future Publ. Co. 1999. 382 p.
5. Pavlov A.N., Hramov A.E., Koronovskii A.A., Sitnikova E.Yu., Makarov V.A., Ovchinnikov A.A. Wavelet analysis in neurodynamics // Physics-Uspekhi. 2012. V. 55, N 9. P. 845–875.

6. Tary J.B., Herrera R.H., van der Baan M. Analysis of time-varying signals using continuous wavelet and synchrosqueezed transforms // *Philosophical Transactions of the Royal Society A Mathematical Physical and Engineering Sciences*. 2018. V. 376. P. 2126–2142.
7. Bespyatov A.B., Bodrov M.B., Gridnev V.I., [et al.]. Experimental observation of synchronization between the rhythms of cardiovascular system, *Nonlinear Phenomena in Complex Systems*. 2003. V. 6. P. 885–893.
8. Koronovskii A.A., Khramov A.E. Wavelet transform analysis of the chaotic synchronization of dynamical systems // *JETP Letters*. 2004. V. 79, N 7. P. 316–319.
9. Ponomarenko V.I., Prokhorov M.D., Bespyatov A.B., [et al.]. Deriving main rhythms of the human cardiovascular system from the heartbeat time series and detecting their synchronization // *Chaos, Solitons and Fractals*. 2005. V. 23. P. 1429–1438.
10. Hramov A.E., Koronovskii A.A., Ponomarenko V.I., [et al.]. Detecting synchronization of self-sustained oscillators by external driving with varying frequency // *Physical Review E*. 2006. V. 73. P. 81–89.
11. Hramov A.E., Koronovskii A.A., Ponomarenko V.I., Prokhorov M.D. Detection of synchronization from univariate data using wavelet transform *Physical Review E*. 2007. V. 75. P. 1–10.
12. Pavlov A.N., Anisimov A.A., Semyachkina-Glushkovskaya O.V., Matasova E. G. and Kurths J. Analysis of blood pressure dynamics in male and female rats using the continuous wavelet transform IOP Publishing // *Physiological Measurement*. 2009. V. 30, N 7. P. 707–717.
13. Kiselev A.R., Gridnev V.I., Karavaev A.S., [et al.]. Evaluation of five-year risk of lethal outcome and development of cardiovascular disorders in patients with acute myocardial infarction on basis of 0.1-Hz rhythms synchronization in cardiovascular system // *Saratov Journal of Medical Scientific Research*. 2010. V. 6, N 2. P. 328–338.
14. Kiselev A.R., Gridnev V.I., Karavaev A.S., [et al.]. Individual approach to antihypertensive drug selection in hypertensive patients based on individual features of autonomic cardiovascular dysfunction // *Arterial Hypertension*. 2011. V. 17, N 4. P. 354–360.
15. Daubechies I., Lu J., Wu H.T. Synchrosqueezed Wavelet Transforms: a Tool for Empirical Mode Decomposition // *Department of Mathematics and Program in Applied and Computational Mathematic*. 2011. V. 30. P. 243–261.
16. Dick O.E., Glazov A.L. Parameters of phase synchronization in electroencephalographic patterns as markers of cognitive impairment // *Journal of technical physics*. 2021. V. 91, N 4. P. 678–688.
17. Dick O.E., Glazov A.L. Estimation of the synchronization between intermittent photic stimulation and brain response in hypertension disease by the recurrence and synchrosqueezed wavelet transform // *Neurocomputing*. 2021. V. 455, N 1. P. 163–177.

КОГНИТИВНЫЕ НАУКИ И ИНТЕРФЕЙС “МОЗГ-КОМПЬЮТЕР”

А.Н. АФОНИН, А.Р. ГЛАДЫШЕВ, А.В. ГЛАДЫШЕВА

Белгородский государственный национальный исследовательский университет
afonin@bsu.edu.ru

СИСТЕМА УПРАВЛЕНИЯ БИОНИЧЕСКОГО ПРОТЕЗА КИСТИ РУКИ НА ОСНОВЕ АДАПТИВНОГО НЕИНВАЗИВНОГО АНАЛИЗАТОРА МЫШЕЧНОЙ АКТИВНОСТИ

Разработана система управления бионическим протезом кисти руки, а также выполнена разработка модели машинного обучения и ее программная реализация для анализа сигналов мышечной активности различной природы с матрицы датчиков. В основе проекта лежит новый подход по реализации комбинированного человеко-машинного интерфейса управления бионическим протезом верхней конечности на основе ЭМГ-датчиков и матрицы пьезодатчиков.

Ключевые слова: *система управления, машинное обучение, бионический протез, человеко-машинный интерфейс, мышечная активность, паттерны движений, пьезодатчик, ЭМГ-датчик.*

Введение

Ежегодно в мире численность инвалидов увеличивается, при этом отдельную категорию составляют люди, лишившиеся конечностей в ходе различных несчастных случаев. По данным на 2020 год Института статистических исследований и экономики знаний ВШЭ официальный статус инвалидности в прошлом году имело около 9% населения. При этом, согласно информации Всемирной организации здравоохранения, фактически доля людей с ограниченными возможностями вдвое больше. В России ежегодно требуются более 60 тысяч протезов рук, а производится в семь раз меньше. Главной целью в данном направлении является создание готового удобного в управлении протеза, который можно купить, надеть и пользоваться без сложного процесса обучения [1].

Можно выделить три основных возможных подхода по реализации управления бионическим протезом:

- использование центральных сигналов (например, электроэнцефалограмма);
- использование промежуточных сигналов (регистрация сигнала с нервов).
- использование конечных сигналов (например, электромиограмма).

Наиболее подходящими как для задачи выделения паттернов двигательной активности с мышц, так и удобства в использовании являются два типа регистрации мышечной активности:

- механическое воздействие, возникающее в результате сокращения мышечных волокон (зоны характерной механической активности). Существует два режима сокращения мышцы: *изотоническое* (изменяется длина волокна, а напряжение остается неизменным) и *изометрическое* (концы мышцы неподвижно закреплены, вследствие чего изменяется не длина, а напряжение). Для определения механических деформаций мышц, возникающих в результате их сокращения, предлагается применить пьезоэлектрические датчики, которые обладают уникальной возможностью воспринимать минимальные по амплитуде механические деформации (до нескольких нанометров), преобразуя их в токи значительной величины.

- электромиография (ЭМГ) – регистрация биоэлектрического потенциала, которое передается от нервной системы к мышцам, отражаясь повышением амплитуды в так называемых двигательных точках – местах наибольшего скопления двигательных единиц. Если снимать биопотенциал в местах расположения двигательных точек, то мы можем получить исходные сигналы для управления протезом. Полоса частот полезного ЭМГ-сигнала составляет от 20 Гц до 500 Гц при амплитуде от 20 мкВ до 2 мВ, при этом у мышц в состоянии покоя амплитуда составляет от 5 до 10 мкВ, у мышц в возбужденном состоянии от 10 до 1000 мкВ.

Используя механическую и электрическую природу сигналов от мышечных сокращений, можно выделить информацию не только о сокращениях крупных мышц, но также выделить отдельные группы, отвечающие за движения, например пальцев кисти руки, тем самым ближе подойти к решению задачи управления каждым пальцем искусственной конечности в отдельности за счет увеличения информативности сигнала. Использование сигналов различной природы позволит получить более достоверную информацию о намерении субъекта осуществить желаемую двигательную функцию. Наличие двух видов датчиков, регистрирующих сигналы различной природы, пригодных для формирования управляющих команд исполнительными

узлами бионических протезов, манипуляторов, экзоскелетов, позволит повысить информативность полезных сигналов, пригодных для формирования управляющих команд, что позволит расширить круг использования.

Постановка задачи и описание алгоритма

Структурно разработанный бионический протез кисти руки состоит из трех отдельных модулей (рис. 1): модуль 1 регистрации и обработки сигнала (анализатор мышечной активности), персонального компьютера 2 и модуля 3 управления исполнительными механизмами отладочного макета искусственной конечности [2].

Основой системы управления анализатора мышечной активности является полнофункциональная отладочная плата, построенная на базе микроконтроллера ATmega328 (модуль 1). В его задачу входит регистрация и оцифровка информации с матрицы датчиков, обмен данными с персональным компьютером (модуль 2) посредством USB интерфейса и Bluetooth-модуля HC-06, вывод необходимой информации на дисплей, управление с помощью кнопочной клавиатуры и энкодера режимами работы анализатора.

В качестве контроллера сбора, накопления экспериментальных данных и анализа используется персональный компьютер (модуль 2), также могут быть использованы микроконтроллеры (например, семейства STM32), контроллеры семейства Arduino, и одноплатные компьютеры, например National Instruments MyRIO и Raspberry Pi.

Основой системы управления макета искусственной конечности кисти руки является полнофункциональная отладочная плата, построенная на базе микроконтроллера ATmega328 (модуль 3). В ее задачу входит набор основных и вспомогательных функций: реализация управления режимами работы сервоприводов; получение и обработка информации с персонального компьютера или другого микроконтроллера посредством USB интерфейса так и Bluetooth-модуля HC-06; реализация отображения информации на OLED дисплее об основных параметрах системы.




Рис. 1. Структура системы управления бионическим протезом кисти руки

В структуре системы управления можно выделить 3 основных этапа обработки информации (рис. 2):

Этап 1 – получение и предварительная обработка информации (включает в себя ЭМГ-датчики с аналогово-цифровым преобразователем, аппаратно-программные средства получения сигналов с матрицы пьезодатчиков).

Этап 2 – анализ, выделение паттернов двигательной активности и формирование команд активации (включает методы и алгоритмы распознавания паттернов двигательной активности).

Этап 3 – реализация двигательных команд исполнительными механизмами макета протеза кисти руки (включает исполнительные механизмы, отвечающие за движение каждого пальца протеза).




Рис. 2. Система управления

Во время выполнения пользователем однотипных двигательных действий в режиме реального времени на персональном компьютере производится обработка и запись сигналов с датчиков (ЭМГ и матрицы пьезодатчиков) в массив данных (DataFrame). Далее на полученном DataFrame (обучающей выборке) производится анализ и выделение общих признаков

(паттернов) двигательной активности при помощи методов и алгоритмов искусственного интеллекта, каждый выделенный паттерн соответствует определенному типу движения (например, сгибание–разгибание кисти руки). Далее производится анализ и выделение паттернов уже на новых данных и при нахождении в них выявленных ранее (из обучающей выборки) признаков, производится передача сигнала активации двигательной команды на исполнительные узлы макета искусственной конечности.

Структурная схема модели машинного обучения представлена на рис. 3.




Рис. 3. Структурная схема модели машинного обучения

Исходными данными являются сигналы, регистрируемые в режиме реального времени с матрицы датчиков анализатора мышечной активности, зафиксированного на предплечье руки пользователя. Тренировочный набор данных формируется из исходных данных при выполнении пользователем различных, чередующихся манипуляций пальцами кисти руки (паттернов) в определенном промежутке времени. При помощи кластеризации тренировочного набора данных происходит деление каждой точки набора данных на кластеры.

Количество кластеров определяется в зависимости от количества выполненных паттернов двигательной активности на этапе формирования тренировочного набора данных или не определяется вовсе. Полученный массив данных подвергается разделению на шум (кластер отсутствия двигательной активности) и новый набор данных, состоящий из последовательности ранее выделенных кластеров, разделенных большими промежутками с шумом.

Далее, определяется общее количество таких групп кластеров нового набора данных, и на основе этого набора формируется целевой набор данных, определяющий количество выделенных групп последовательности кластеров с присвоение каждой такой группе определенной метки (целевого значения). Например, если изначально выполнялось три вида двигательной активности (паттерна) и каждая повторялась по шесть раз в результате кластеризации с дальнейшим разделением на группы и шум, количество таких групп получилось равным 36, то такой целевой набор данных будет формироваться из 6 значений (например, от 0 до 5), повторяющихся 6 раз.

Используя набор с целевыми значениями и набор с группами последовательностей кластеров, можно создать и обучить модель классификации и использовать уже эту модель для анализа новых (поступающих) в режиме реального времени данных для выявления паттернов, изначально созданных на этапе формирования тренировочного набора данных. Для оценки корректности работы рабочей модели, предназначен тестовый набор данных.

Данная система управления исполнительными узлами искусственной конечности на основе синтеза информации от пьезодатчиков и ЭМГ-датчиков обеспечит снижение количества ошибок, а также позволит расширить функциональные возможности протезов.

Проведены эксперименты по выявлению с помощью полученной модели машинного обучения паттернов движений пальцев кисти на основе информации матрицы датчиков регистратора физиологических сигналов мышечной активности (рис. 4). Тестирование и отладка работы анализатора мышечной активности выполнялись на персональном компьютере при помощи среды Python IDLE. Устройство фиксировалось на запястье руки человека при помощи застежки, обеспечивающей плотный контакт матрицы пьезодатчиков и ЭМГ датчиков с поверхностью кожи, так чтобы один ЭМГ датчик располагался с внутренней стороны предплечья, а другой с внешней. Пользователь активировал питание устройства. После того как установилась связь между компьютером и анализатором мышечной активности, пользователь начинал выполнять ряд однотипных движений (паттерн) пальцами кисти руки в течение определенного времени с записью сигналов в набор данных (DataFrame) тестовой выборки [3, 4].




Рис. 4. Анализатор мышечной активности

Первый эксперимент выполнялся при выполнении действий сгибания-разгибания кисти руки в 10-секундном интервале времени. Результаты кластеризации соответствующего DataFrame, созданного за время выполнения паттернов двигательной активности, полученные при помощи метода *k*-средних, агломеративной кластеризации и метода DBSCAN, представлены на рис. 5.

KMeans принадлежность к кластерам:

```
[1 1 1 1 1 0 1 1 1 1 2 1 1 1 1 1 1 0 0 1 1 1 1 1 2 1 1 1 1 1 0 0 0 1 1
 1 1 2 1 1 1 1 1 1 1 1 0 0 0 1 1 1 1 2 2 1 1 1 1 1 1 1 1 0 0 0 1 1 1 1 2 2 1 1
 1 1 1 1 1 0 0 0 1 1 1 1 2 2 1 1 1 1 1 0 0 0 1 1 1 1]
```

AgglomerativeClustering принадлежность к кластерам:

```
[1 1 1 1 1 0 1 1 1 1 2 1 1 1 1 1 1 0 0 1 1 1 1 1 2 1 1 1 1 1 0 0 0 1 1
 1 1 2 1 1 1 1 1 1 1 0 0 0 1 1 1 1 2 2 1 1 1 1 1 1 1 0 0 0 1 1 1 1 2 2 1 1
 1 1 1 1 1 0 0 0 1 1 1 1 2 2 1 1 1 1 1 0 0 0 1 1 1 1]
```

DBSCAN принадлежность к кластерам:

```
[ 0 0 0 0 0 -1 0 0 0 -1 -1 0 0 0 0 0 0 -1 -1 -1 0 0 0 0
 0 -1 -1 0 0 0 0 0 -1 -1 -1 0 0 0 -1 -1 0 0 0 0 0 -1
 -1 -1 0 0 0 -1 -1 0 0 0 0 0 0 -1 -1 -1 0 0 0 -1 -1
 0 0 0 0 0 0 -1 -1 -1 0 0 0 -1 -1 0 0 0 0 -1 -1 -1
 0 0 0 0]
```

Рис. 5. Результаты кластеризации

Изначально было задано 3 кластера: отсутствие движений, сгибание, разгибание кисти руки. Кластер под номером 1 отвечает за отсутствие двигательной активности, кластер под номером 0 за сгибание пальцев кисти руки, кластер под номером 2 за разгибание кисти руки (рис. 5). Иссле-

двух третий массив DBSCAN, несложно заметить, что сумма подряд стоящих значений 1 чередуется с четной на нечетную, что как раз и характеризует 2 типа действия – сгибание и разгибание кисти руки, а значение 0 является значением, характеризующее отсутствие двигательной активности.

Прогнозы на тестовом наборе по всем методам показали хорошие результаты по выделению паттернов в первом эксперименте. На рис. 6 представлен прогноз по выделению паттернов из новых, поступающих в режиме реального времени данных.

```
Python 3.8.1 (tags/v3.8.1:1b293b6, Dec 18 2019, 22:39:24) [MSC v.1916 32 bit (Intel)] on win32
Type "help", "copyright", "credits" or "license()" for more information.
>>>
===== RESTART: C:\Users\Acer\Рабочий стол\Python Analizator\Kneuborn.py =====
KMeans принадлежность к кластерам:
[0 0 0 0 0 2 0 0 0 0 1 0 0 0 0 0 0 0 2 2 0 0 0 0 0 1 0 0 0 0 0 0 2 2 2 0 0
 0 0 1 0 0 0 0 0 0 0 2 2 2 0 0 0 0 1 1 0 0 0 0 0 0 0 2 2 2 0 0 0 0 1 1 1 0 0
 0 0 0 0 0 2 2 2 0 0 0 0 1 1 0 0 0 0 0 0 2 2 2 0 0 0 0]
Прогнозы на тестовом наборе: [0 1 0 1 0 2 0 0 1 2 0 0 0 0 0 0 0 0 2 0 0 0 0 1 0]
Правильность на тестовом наборе: 1.000
>>> |
```

Рис. 6. Прогноз по выделению паттернов из новых, поступающих в режиме реального времени данных

Правильность составила 100%, из чего можно сделать вывод, что модель эффективно работает на новом наборе данных.

Второй эксперимент выполнялся при выполнении следующих действий: 3 различных комбинаций открытий – закрытия кисти руки в течение 1 минуты 20 с в течение 1 минуты 20 секунд. В данном эксперименте уже количество искомых кластеров равняется 7, но на этот раз каждый вид двигательного действия есть комбинация набора чередующихся кластеров и уже усложняется выделение паттернов движений, для чего потребуется использование других моделей машинного обучения или их комбинации. Проведя анализ результатов кластеризации, используя методы: kmeans, DBSCAN, MeanShift, SpectralClustering и GaussianMixture, можно выделить наиболее информативный (большее количество кластеров на один паттерн) – GaussianMixture.

Собрав все выделенные группы кластеров в отдельный набор данных и присвоив каждой повторяющейся группе свою метку, обучим модель классификации алгоритмом K-средних на полученных данных (обучающий набор образцов – cluster_Sp и обучающий набор целевых значений – target) и вызовом функцию оценщика (рис. 7) [5].

```
clf.fit(cluster_Sp,target)
print("Прогнозы на тестовом наборе: {}".format(clf.predict(cluster_Sp)))
print("Правильность на тестовом наборе: {:.3f}".format(clf.score(cluster_Sp, target)))
```

Прогнозы на тестовом наборе: [1 2 3 4 5 6 1 2 3 6 5 6 1 2 3 4 5 6 1 2 3 4 5 6 1 2 3 4 5 6 1 2 3 4 5 6 1 2 3 6 5 6]
Правильность на тестовом наборе: 0.944

Рис. 7. Прогноз на тестовом наборе

Выводы

Правильность на тестовом наборе составила 94.4% и можно сделать следующий вывод, что предложенная модель хорошо справляется с распознаванием паттернов двигательной активности в данном эксперименте.

Результаты исследования могут быть использованы при построении человеко-машинного интерфейса для систем управления бионическими протезами кисти руки или экзоскелетами.

Список литературы

1. <https://tiflocentre.ru/stati/statistika-po-invalidnosti.php>
2. <https://studfiles.net/preview/5554364/page:17/>
3. <https://coderlessons.com/tutorials/python-technologies/uznaite-mashinnoe-obuchenie-s-python/ml-algorithm-klasterizatsii-k-srednikh>
4. Afonin A.N., Aleynikov A.Y., Nazarova M.Y., Gladishev A.R., Gladisheva A.V. Bionic hand prosthesis with an improved muscle activity analyzer // Biointerface Research in Applied Chemistry. 2018. V. 8, N 5. P. 3514–3517.
5. Müller A.M., Sara Guido S. Introduction to Machine Learning with Python: A Guide for Data Scientists. O'Reilly Media, Inc. 2016. 400 p.

В.А. ГАНЕЕВА¹, Э.С. КЛЫШИНСКИЙ²

¹Национальный исследовательский университет «Высшая школа экономики»,
Москва

²Институт прикладной математики им. М.В. Келдыша РАН, Москва
eklyshinsky@hse.ru

**ИССЛЕДОВАНИЕ ИНТЕРПРЕТАЦИОННЫХ СВОЙСТВ
СТАТИЧЕСКИХ ВЕКТОРНЫХ МОДЕЛЕЙ ДЛЯ РУССКОГО
ЯЗЫКА**

Рассматривается задача семантической интерпретации внутреннего эмбединг-слоя моделей word2vec. Алгоритм-выделение семантически интерпретируемых осей на основе LSA предложен и проверен на трёх разных моделях до третьего уровня разделения. Анализ семантического разделения осуществляется с привлечением словарей по предметным областям. Сделан вывод об интерпретируемости расположения слов в статических моделях.

Ключевые слова: *латентно-семантический анализ, word2vec, интерпретация векторного пространства.*

Введение

Задача векторизации текстов имеет длинную историю. Идея описания слова в виде вектора признаков высказывалась еще в середине XX века. Так, в работах [1] и [2], где был введен термин «контекстный вектор», исследовалось контекстное распределение ограниченного списка слов, однако векторные представления слов создавались вручную.

Актуальность проблемы представления слова в виде вектора в низкоразмерном пространстве росла вместе с ростом интереса к нейронным сетям. Рост размеров входного словаря анализируемых слов означал увеличение числа параметров нейронной сети, то есть снижение скорости ее обучения. В 1996 году в работе [3] был предложен метод новой кластеризации слов. Метод использовал латентно-семантический анализ (LSA) для расчета векторов в некотором латентном пространстве. В работе [4] было предложено использовать косинусную меру сходства для поиска синонимов и антонимов. В ней же было явно указано, что латентно-семантический анализ проводит снижение размерности пространства, сам размер пространства выбирался исходя из эмпирических соображений. Помимо этого, было показано, что сходные слова должны находиться в

примерно одной области семантического пространства. Это первые известные нам работы, в которых предлагается проводить сокращение размерности пространства признаков, преобразовывая представление слов в виде векторов с размерностью размера словаря (то есть десятки и сотни тысяч слов) к размеру некоторого латентного семантического пространства размерностью в несколько сотен параметров.

Следующим шагом стало использование собственно нейронных сетей для построения векторов в латентном пространстве. В 2003 году в работе [5] было предложено использовать двухслойный персептрон для формирования векторного представления слов, который получался из унитарного векторного представления сочетаний данного слова со всеми остальными словами из словаря. В [6] было предложено изменить вид целевой функции, что снизило вычислительную сложность задачи.

В 2013 году был опубликован метод, названный Word2Vec [7] и ставший прорывом в области получения векторов. Он продолжал идеи дистрибутивной семантики и позволял строить вектор для слова, исходя из сходства контекстов употребления слов. Главным достижением работы стала гипотеза о том, что в качестве функции потерь при обучении нейронной сети можно использовать функцию, оценивающую расстояние между точками в исходном и редуцированном пространствах. Также предлагалось снизить вычислительную сложность задачи за счет использования не всех слов, а нескольких самых близких и части дальних.

Одним из свойств языка является семантическая неоднозначность некоторых слов. Модель Word2Vec всегда возвращает один вектор, то есть не учитывает контекста употребления слова, раскрывающего его смысл. В связи с этим такие модели, как Word2Vec, называются *статическими*. Для исправления этого недостатка были предложены модели ELMO [8] и BERT [9], называемые *контекстуализированными*. Для получения вектора им необходимо подать всё предложение целиком, а вектор слова будет определяться исходя из его ближайшего окружения.

В работе [7] было замечено, что полученное векторное пространство позволяет решать задачу аналогий. Оказалось, что можно найти вектор, который переводит набор слов в их аналоги, то есть отвечает за преобразование некоторого признака. В качестве примера использовались столица и соответствующая ей страна, названия представителей профессий разного пола, некоторые другие аналогии.

Достаточно скоро стало ясно, что задача аналогий часто дает сбой и не работает для произвольной области [10]. В работе [11] утверждается, что проблема может крыться и во взаимном расположении векторов, напри-

мер, в высокой косинусной близости некоторых пар слов, и, наоборот, в большом косинусном расстоянии среди других пар, что может влиять на точность решения. В работах, исследующих точность решения задачи аналогий для статических [12] и контекстуализированных [13] векторных представлений, было показано, что, несмотря на разброс как в расстояниях, так и углах между векторами понятий, в целом можно выделить некоторые направления с очевидной интерпретацией. Из наличия вектора, переводящего название должности из мужского в женское, следует, что на одном его конце находятся мужчины, а на другом – женщины. То же самое можно утверждать и для любого другого успешно работающего вектора аналогий. Однако чаще всего рассматриваемые аналогии являются довольно узкими.

Помимо этого, векторные пространства не показывают границы группировки слов по каким-либо признакам. Этот недостаток исправляется, например, при помощи тематического моделирования [14], решающего сразу несколько задач: определение тематик текста; выделение ключевых слов для этих тематик; векторизация текстов с приписыванием степени их принадлежности тематикам. Тематики могут объединяться в иерархию, хотя и небольшой глубины [15]. Подобный подход позволяет интерпретировать набор текстов, проводить их противопоставление, сравнение и категоризацию, но не позволяет как-то интерпретировать и находить направления в семантическом пространстве.

Итак, существующие векторные представления позволяют группировать слова по их смысловому сходству. Помимо этого, в пространстве имеются некоторые выделенные направления, показывающие, что слова разделяются по некоторым признакам. Однако поиск подобных признаков и их иерархическая группировка на самом высоком уровне абстракции являются нетривиальной задачей.

В данной работе мы показываем возможность смысловой интерпретации расположения больших групп слов для векторной модели в целом. Для этого предлагается выделять направления, наиболее пригодные для подобной интерпретации, при помощи метода LSA. Эксперименты с русскоязычными моделями подтвердили корректность нашей гипотезы.

Метод исследования интерпретируемости пространства Word2Vec

Для исследования мы использовали векторные представления из статических моделей Word2Vec. За счет этого имеется возможность зафиксировать семантическое пространство и исследовать его свойства. На вход модели BERT подается предложение, задающее контекст слов.

Для получения векторов здесь потребуется большое количество специально подобранных текстов, обеспечивающих полноту репрезентации всех исследуемых слов. Подбор такой коллекции текстов представляет собой серьезную задачу. Сами вектора при этом будут отличаться, что порождает проблему кластеризации слов и усреднения их векторов. В связи с этим мы отказались от контекстуализированных моделей и использовали статические. Интерпретация статической модели FastText затруднительна, так как она хранит только фрагменты слов.

В данной работе мы проверяем гипотезу существования в статическом векторном пространстве локальных (небольшие группы слов) и глобальных (модель в целом) направлений, разделяющих слова по некоторому признаку. Сами признаки могут относиться не только к семантике, но и к прагматике, дискурсу, отражать особенности встречаемости, контекстов их употребления. Главным свойством направлений должна являться разделимость: слова, расположенные в разных концах некоторого вектора, могут быть противопоставлены по выделенному признаку. В отличие от задачи аналогии, нашей целью является введение некоторой шкалы вместо простой фиксации направления и расстояния.

Лучшей разделимостью обладают направления с большей относительной дисперсией. Это, например, случай двух компактных далеко расположенных кластеров или равномерного распределения. В такой ситуации можно провести одну или несколько разделяющих поверхностей, которые гарантированно разделят различающиеся объекты. Подобные направления хорошо выделяет метод латентного семантического анализа.

Опишем предлагаемый нами метод. Пусть дан словарь слов $\mathbf{d} = \{\mathbf{w}_i\}$, по которым можно получить вектора Word2Vec и сформировать из них матрицу $E = \text{Word2Vec}(\mathbf{d})$. Пусть счетчик числа пройденных шагов $n = 1$. К матрице E и словарю $\mathbf{d}$ можно применить алгоритм разделения слов.

1. При помощи алгоритма LSA для матрицы E получим матрицу векторов в преобразованном пространстве $R = \text{LSA}(E)$.

2. Выделим из матрицы R вектор номер n : $\mathbf{r} = R_n$.

3. Отсортируем все слова по их значениям в $\mathbf{r}$: $\mathbf{w}' = \text{argsort}(\mathbf{w}, \mathbf{r})$.

4. Разделим $\mathbf{w}'$ на три части в соответствии со значениями $\mathbf{r}$: $\mathbf{d}' = \langle \mathbf{d}^-, \mathbf{d}^0, \mathbf{d}^+ \rangle$. Положим $n = n + 1$. До достижения необходимого уровня вложенности рекурсивно применим алгоритм разделения слов по главной оси к словарям $\mathbf{d}^-$ и $\mathbf{d}^+$ и соответствующим им матрицам E^- и E^+ .

Итогом работы алгоритма будет иерархия осей (векторов), задающих принципы разделения пространства. Сама иерархия будет представлять собою дерево, в котором некоторые направления могут иметь сходную

интерпретацию, однако в общем случае подобное сходство не является обязательным. Эта иерархия будет последовательно разделять слова по признакам, переходя от более общих (глобальных) к более частным (локальным). Логика подобного разделения становится очевидна из общих рассуждений. Слова в разных концах оси обладают принципиально разной семантикой. Так, если на первом шаге мы получим разделение по оси “материальное-нематериальное”, то объекты материального мира будут обладать массой, линейными размерами, материалом, тогда как нематериальные объекты этими характеристиками обладать не должны. В связи с этим, мы не можем брать сразу несколько первых собственных векторов с самыми большими собственными значениями. Более того, эксперименты показали, что каждый раз, когда мы разделяем пространство на части, мы не можем брать только первый собственный вектор, а должны брать следующий по очереди, так как первый собственный вектор примерно совпадает по всем выделяемым подпространствам (как минимум, совпадают выделяемые ими слова).

Заметим, что существует несколько вариантов разделение словаря на части. Первый – разделение интервала от минимального до максимального значений из $\mathbf{r}$ на три равные части. Второй – использование статистических характеристик: к словарям $\mathbf{d}^-$ и $\mathbf{d}^+$ будут относиться слова, отклоняющиеся от среднего значения больше чем на дисперсию. Эти методы определяют границу строго и разделяют близкие слова. В связи с этим мы предлагаем следующий алгоритм. Все слова в словаре кластеризуются при помощи метода k -средних на число кластеров, сопоставимое с числом слов, например $|\mathbf{d}|/5$. Далее граница проводится по границам кластеров, становится размытой, но близкие по смыслу слова остаются вместе.

Анализ результатов

В этой части статьи под словарем будем понимать список слов, полученный в результате разделения списка слов вдоль выделенной оси. Под категорией будем понимать список слов, сгруппированных по тематике. На основе Wiktionary мы составили списки слов, состоящих из разной лексики (научной и бытовой, технической и гуманитарной, архаичной и современной) из следующих категорий: геология, география, минералы, растения, оружие, искусства, филология, философия, информатика, архитектура, фортификация, геологические эпохи, политика, профессии, ранги, занятия, имена мужские и женские, устаревшие слова, российские города и реки, одушевлённые существительные. Эти категории использовались для контроля разделения словарей по тематикам.

Наличие списков слов по категориям позволяет визуализировать разделение слов по словарям. На каждом уровне разделения будем анализировать только слова, попавшие в словари $\mathbf{d}^-$ и $\mathbf{d}^+$, пропуская при этом словарь $\mathbf{d}^0$. Для каждого уровня построим тепловую карту, в которой столбец будет сопоставлен со словарем соответствующего уровня, а строка – одной из категорий. В каждой ячейке будет показана доля слов из категории, попавшая в данный словарь. Заметим, что сумма долей по строке не должна равняться 1, так как часть слов могут попадать в словарь $\mathbf{d}^0$.

Приведем пример визуализации для предобученной модели `ruscorgora_upos_cbow_300_20_2019` сайта `rusvectors.org`, обученной на тексте Национального корпуса русского языка (смесь беллетристики разных веков, новостей, Википедии, текстов разговорного жанра). Результаты показаны на рис. 1, иерархию разделения можно увидеть в табл. 1.

Абстрактные понятия представлены следующими словами. Блок «Духовное»: *добродетель, токмо, чувствование, наставление, прилежание, поелику, житие*. Блок «Общественное»: *лозунг, сторонник, конфликт, пропаганда, капитализм, фашизм, война*. Блок «Развлечения»: *фестиваль, шоу, чемпионат, фильм, чемпион, компьютер, экран*. Блок «Наука»: *введение, хозяйство, доход, ведение, распоряжение, увеличение, принятие*.




Рис. 1. Визуализация третьего уровня разбиения для модели `ruscorgora_upos_cbow_300_20_2019`

Таблица 1

Иерархия разделения словарей по уровням

Неконкретное (термины, категории, абстракции)				Конкретное			
Духовное, внутренний мир		Производство, прикладные науки		Архаичное		Современное	
Духовное	Общественное	Развлечения	Наука	Книжное архаичн.	Бытовое архаичн.	Книжное соврем.	Бытовое соврем.

Интерпретируемость результатов на более глубоких уровнях также присутствовала. Мы не можем утверждать, что по каждому из направлений слова выстроились по уровню соответствия, так как метод LSA фактически проводил проекцию многомерного пространства на одну ось, но глобальная структура слов соблюдалась.

Мы также провели эксперименты для модели `araneum_upos_skipgram_300_2_2018` (см. табл. 2). Корпус Araneum содержит тексты из форумов и социальных сетей (что нашло отражение в разделии блока «Абстрактное»), научные и аналитические статьи (раздел «Организации, правовое регулирование») и значительно меньший процент беллетристики (соответствующая лексика в разделии верхнего уровня не представлена).

Таблица 2

Иерархия разделения словарей по уровням

Люди, социальное регулирование				Организации, правовое регулирование			
абстрактное		конкретное		технологии производства		управление и производство	
оскорбления	духовный мир	имена	природа	химия и биология	физика, автоматизация	экономика	Полит. и обществ.

Полученные здесь результаты дают разделение, отражающее специфику текстов. Заметим, что второй уровень разделения более «гуманитарной» составляющей повторяет разделение для предыдущей модели на верхнем уровне на абстрактные и конкретные понятия. Следовательно, некоторые направления в моделях могут повторяться.

Мы также обучили собственную модель на текстах научных статей. Здесь на первом уровне наблюдалось разделение бытовой лексики (терминов, которые могут встретиться не только в научных текстах) и научно-

го дискурса (фамилии учёных и авторов статей, названия институтов, университетов и других образовательных и научных учреждений, города их расположения, сложные научные термины, например *интертекстуальность* или *линеаризация*). Например, *стих* наблюдается в бытовой группе, а *дольник* или *акростих* – в научной. На втором уровне слова разделились на относящиеся к общественному устройству и культурной жизни против предметного мира (в т. ч. естественных наук) – части тела, растения, оружие и орудия труда. Слова, относящиеся к научному дискурсу, разделились на абстрактные научные термины без физического референта и на группу с фамилиями, организациями и др. Заметим, мы вновь встречаем здесь разделение на абстрактное и конкретное.

На следующем этапе слова об обществе и культуре разделились на слова о политике, экономике, государственном и общественном устройстве и на группу о философии и филологии – на группы о внутреннем мире человека и его взаимодействии с обществом (то есть мы снова наблюдаем разделение на общественное и духовное). Группа объектов физического мира разделилась на более терминологические объекты и более бытовые. Группа терминов, фигурирующих в научном дискурсе, разделилась на специальности, явления и процессы, происходящие с науками или научными дисциплинами, и на процессы и явления, происходящие с объектами науки. Группа имен учёных, географических названий и организаций разделилась на имена учёных и на города, страны и организации. Получается, что первые три выделяемых уровня более абстрактны, чем направления науки, и более привязаны к контексту употребления слов, чем к их предметной области.

Выводы

Исходя из вышеизложенного, мы можем утверждать, что метод LSA, примененный к статическим векторным моделям, позволяет выделить направления, обладающие возможностью смысловой интерпретации. Полученные направления интерпретируются как семантически, так и дискурсивно. Например, разделение по областям науки мы получаем на гораздо более низком уровне, чем разделение по сфере употребления (общенаучная и общеупотребимая лексика против специфичной терминологии предметных областей). Сама же терминология сначала разделяется на базовую (входящую в область базовых понятий) и узкоспециальную, и лишь потом – на терминологию предметных областей. Следовательно, что на верхнем (глобальном) уровне эти направления обладают высоким уровнем абстракции. В целом это согласуется с дистрибутивной гипоте-

зой, на которой основываются языковые модели.

Также выяснилось, что термины, записанные в Wiktionary в качестве научной терминологии, по большей части отражают лишь наиболее популярные понятия (попавшие в общеупотребительную лексику) или имеют отношения к дисциплинам, которые проходятся в качестве общей профессиональной подготовки. Более сложные и конкретные термины представлены в них незначительно.

Предложенный алгоритм был проверен на трёх вариантах моделей word2vec, и для всех моделей выделенные направления интерпретировались согласно их значению и сфере употребления. Также выяснилось, что разделение семантического пространства существенно зависит от текстов, поданных на вход модели. Это может быть связано как с контекстами употребления слов, задающими расположение терминов в итоговом пространстве, так и с частотой встречаемости терминов в текстах. Последнее утверждение хорошо соотносится с работами в этой области [16].

В дальнейшем нам предстоит исследовать влияние метода определения границы на точность работы метода. Открытым остается вопрос о результатах разделения слов после большего числа итераций. Мы оставили без интерпретации среднюю часть каждого разделения, так как слова в ней расположены чрезвычайно плотно. Наконец, исследования требуют интерпретируемость контекстуализированных моделей.

Итак, предложенный метод позволяет интерпретировать векторное пространство статических языковых моделей, при этом выделенные признаки разделения обладают высоким уровнем абстракции.

Список литературы

1. Osgood C., Suci G., Tannenbaum P. The measurement of meaning. University of Illinois Press. 1957. 342 p.
2. Gallant S. Context vector representations for document retrieval // Proc. of AAAI Workshop on Natural Language Text Retrieval. 1991.
3. Bellegarda J.R., Butzberger J.W., Chow Y.L., Cocco N.B., Naik D. A novel word clustering algorithm based on latent semantic analysis // Proc. of ICASSP-96. 1996. V. 1. P. 172–175.
4. Cocco N., Jurafsky D. Towards better integration of semantic predictors in statistical language modeling // Proc. of ICSLP-98. 1998. V. 6. P. 2403–2406.
5. Bengio Y., Ducharme R., Vincent P., Jauvin P. A Neural Probabilistic Language Model // Journal of Machine Learning Research. 2003. V. 3. P. 1137–1155.
6. Collobert R., Weston, J. A unified architecture for natural language processing // Proceedings of the 25th International Conference on Machine Learning, 2008. V. 20, I. 1. P. 160–167.

7. Mikolov T., Chen K., Corrado G., Dean J. Distributed Representations of Words and Phrases and their Compositionality // NIPS, 1–9 Neural Information Processing Systems 26: 27th Annual Conference on Neural Information Processing Systems. 2013. P.3111–3119.
8. Peters M.E., Neumann M., Iyyer M., Gardner M., Clark C., Lee K., Zettlemoyer L. Deep contextualized word representations // arXiv preprint arXiv:1802.05365 (<https://arxiv.org/abs/1802.05365>)
9. Devlin J., Chang M.-W., Lee K., Toutanova K. BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding // arXiv preprint arXiv:1810.04805v2 (<https://arxiv.org/abs/1810.04805v2>)
10. Levy O., Goldberg Y. Linguistic Regularities in Sparse and Explicit Word Representations // Proceedings of the Eighteenth Conference on Computational Natural Language Learning. 2014. P. 171–180.
11. Rogers A., Drozd A., Li B. The (Too Many) Problems of Analogical Reasoning with Word Vectors // Proceedings of the 6th Joint Conference on Lexical and Computational Semantics. 2017. P. 135–148.
12. Korogodina O., Karpik O., Klyshinsky E. Evaluation of Vector Transformations for Russian Word2Vec and FastText Embeddings // Conference on Computer Graphics and Machine Vision: GraphiCon 2020. 2020. V. 2744. P. paper 18–1 – paper 18–12.
13. Korogodina O., Koulichenko V., Karpik O., Klyshinsky E. 2021. Evaluation of Vector Transformations for Russian Static and Contextualized Embeddings // Conference on Computer Graphics and Machine Vision: GraphiCon 2021. 2021. V. 3027. P. 349–357.
14. Воронцов К. В., Потапенко А. А. Регуляризация вероятностных тематических моделей для повышения интерпретируемости и определения числа тем // Компьютерная лингвистика и интеллектуальные технологии: По материалам ежегодной Международной конференции «Диалог». М.: Изд-во РГГУ, 2014. Вып. 13 (20). С. 676–687.
15. Chirkova N.A., Vorontsov K.V. Additive regularization for hierarchical multimodal topic modeling // Journal Machine Learning and Data Analysis. 2016. V. 2, N 2. P. 187–200.
16. Shavrina T. Word vector models as an object of linguistic research. Computational Linguistics and Intellectual Technologies // Proceedings of the International Conference “Dialogue 2019”. 2019. P. 576–588.

A.A. DEMCHEVA^{1,2}, A.M. KORSAKOV¹, A.V. BAKHSHIEV²

¹ Russian State Scientific Center for Robotics and Technical Cybernetics, St. Petersburg

² Peter the Great St. Petersburg Polytechnic University
a.demcheva@rtc.ru, a.korsakov@rtc.ru, palexab@gmail.com

PAIN SENSATION MODEL BASED ON THE COMPARTMENT SPIKING NEURON MODEL (CSNM)*

The paper considers a pain sensation model based on the Gate control theory by R. Melzak and P.D. Wall. The model is defined through the use of CSNM (Compartment Spiking Neuron Model), which allows to describe and change the structure of a neuron online (cell body size, number and length of dendrites, number of synapses) depending on incoming spiking pattern. The performance of the model was evaluated with solving the binary classification problem. The results have shown the 99.3% classification accuracy. The proposed model can be used in neuromorphic systems as a part of system state control or behavioral functions implementation as well as a NOT logic gate.

Keywords: *spiking neural network, spiking neuron model, compartment neuron model, model of pain, gate control theory, neuromorphic systems.*

Introduction

In biological organisms, pain is an important mechanism of protection and self-regulation since it serves as a signal of damage or nervous disruption. A similar mechanism may also be useful for technical systems. The implementation of pain in neuromorphic systems can perform the functions of internal state control and emergencies notification. In this paper we propose a pain sensation model based on the main features of the Gate control theory [1].

The CSNM (Compartment Spiking Neuron Model) [2] was used as the basis of the proposed model. Spiking neural networks have high noise immunity and energy efficiency, which is achieved by encoding information using pulses (spikes). Unlike the existing spiking neuron models, CSNM has the ability to structural adaptation. The simulation was performed using the software platform [3].

* The work was carried out as the part of the state task of the Russian Ministry of Education and Science No. 075-01623-22-00 "Research and development of a biosimilar system for controlling the behavior of mobile robots based on energy-efficient software and hardware neuromorphic tools".

Gate Control Theory

The proposed pain sensations model is based on the theory by R. Melzak and P.D. Wall [1]. According to this theory, the substantia gelatinosa acts as a gate control system that modulates the synaptic transmission of nerve impulses from peripheral fibers to central cells (see Fig. 1a). The fibers project to substantia gelatinosa (SG) and first central transmission (T) cells. The inhibitory effect exerted by SG on the afferent fiber terminals is increased by activity in large fibers (L) and decreased by activity in small fibers (S). The central control trigger is represented by a line running from the large-fiber system to the central control mechanisms. These mechanisms, in turn, project back to the gate control system. The T cells project to the entry cells of the action system, which forms complex behavioral reactions to pain.




Fig. 1. Schematic diagram of the pain sensations model: (a) gate control theory by R. Melzak and P.D. Wall; (b) the proposed pain sensation model

Pain Sensation model based on CSNM

The main feature of CSNM is the ability to form a required neuron response by operating with such discrete hyperparameters as neuron size, dendrite lengths and the number of excitatory or inhibitory synapses, without basic parameters tuning. A detailed mathematical description of CSNM can be found in [2].

The Fig. 1b shows the structural scheme of proposed pain sensation model, where B^i is a soma compartment, $D^{i,j}$ is a dendrite compartment, i is a neuron dendrite number, j is a dendrite compartment number and G is an action potential generator. X is a spiking pattern, which represents the only input of the model. A single spike A serves as a starting mechanism for the *Self-oscillator* block and comes to the input once in a modeling time. The *Self-oscillator* block contains a ring structure with feedback, which provides contin-

uous spike generation. The spike signal generated by *Self-oscillator* goes to the excitatory synapse of the *Inverter* neuron.

Stimulus is a neuron with ability to structural adaptation [4]. It compares an input spiking pattern X to the sample pattern it was previously trained in, and generates an output spike, if X differs from the training sample by no more than a specified value (can be specified by setting the threshold potential of the *Stimulus* neuron). The output of this neuron is connected to the inhibitory synapse of the only soma compartment of the *Inverter* neuron. If X is a pattern, which is close to the training example, the firing of *Stimulus* neuron has an inhibitory effect on the *Inverter* neuron. It suppresses the excitatory effect from the *Self-oscillator* block, so the *Inverter* neuron does not fire and there is no signal at the output of the model. On the contrary, if X differs from the training sample by more than a specified value, the *Stimulus* neuron inhibitory effect does not occur, and the *Inverter* neuron begins firing (output signal Y).

Thus, an ordinary situation is considered to be receiving a pattern, which is close to the training sample. In this case, the model does not react. An alarming situation is considered to be receiving a pattern, which differs from the training example by more than a specified value — in this case, the model generates a warning signal.

In the proposed model, a trained *Stimulus* neuron acts as a substantia gelatinosa (SG), regulating the intensity of the *Inverter* neuron stimulation. The activity of afferent fibers (L and S) is modeled by applying a spike signal generated by *Self-oscillator* to the excitatory input of the *Inverter* neuron. The *Inverter* neuron itself represents the first central transmission cells (T).

The main difference between the proposed model and the Gate Control theory is the absence of a Central control block, whose functions are biologically performed by the brain. Another difference is that in the proposed model the activity of afferent fibers does not affect the substantia gelatinosa functioning.

Software implementation of the model

The proposed pain sensation model was implemented on the software platform [3]. The model is represented in the library by the *NOTGate* block (see Fig. 2).

The *Source* block generates a single spike A (see Fig. 1b), which starts the operation of the *Self-oscillator* consisting of *Neuron1* and *Neuron2* blocks. The outputs of *Neuron1* and *Neuron2* are connected to excitatory synapses of each other, so to form a ring structure that implements continuous spike generation. The dendrite lengths and the number of excitatory synapses for these neurons are set by the parameters *DendriteLengthNGen1*, *NumExcSynapsesNGen1* and

DendriteLengthNGen2, *NumExcSynapsesNGen2*, respectively. Tuning these parameters allows adjusting the excitation intensity of the *Self-oscillator* neurons and thus setting the frequency of the excitatory signal coming to the *Neuron* block (*Inverter* neuron).




Fig. 2. Structural scheme of the *NOTGate* block

The *NeuronTrainer* block corresponds to *Stimulus* neuron. The input pattern X is defined by the *InputPattern* parameter, which should contain the input signal delays for each of dendrites (in seconds). The dimension of the pattern should be equal to the number of dendrites and by default is set to four. The *IsNeedToTrain* parameter of *NeuronTrainer* block indicates the end of learning process (if false, learning is finished).

The *PatternSource* block maintains the inhibitory effect from *NeuronTrainer* by repeating the received spike with a given frequency (can be specified by setting the *PatternFrequency* parameter) for a certain time. In this study, the duration of the input spike-repeating period was defined as follows:

$$T_{\text{PattMode}} = \frac{1}{f_{\text{Spikes}}} - \Delta \quad (1)$$

where f_{Spikes} is the firing frequency of the trained neuron (specified by setting the *SpikesFrequency* parameter of the *NeuronTrainer* block), Δ is the pulse duration of the *PatternSource* generator (specified by setting the *PulseLength* parameter). This condition ensures the complete suppression of the excitatory effect from *Self-oscillator* block on the *Inverter* neuron. The sensitivity of the model can be configured by setting the threshold potential of the *NeuronTrainer* block (*LTZThreshold* parameter).

Experiments. Analysis of model reactions to input patterns

The parameter values used in the simulation are shown in Table 1. As a

training sample, the following pattern was used: [0; 0.03; 0.06; 0.09].

Fig. 3 shows the simulation results. A single spike from the *Source* block (1) starts the operation of the *Self-oscillator* blocks: *Neuron1* (2) and then *Neuron2* (3). At the initial moment, the *NeuronTrainer* block is not trained and is not capable of pattern recognition. Consequently, there is no inhibitory effect on *Neuron* block (4), so there is an alarm signal at the output of the model (6).

The moment of training completion is shown in the figure by the arrow. Since the input pattern still coincides with the training sample, the *NeuronTrainer* block begins to generate a response signal (4), maintained by operation of the *PatternSource* block (5). The resulting inhibitory effect suppresses the influence from *Self-Oscillator*, so the alarm signal stops (6).

Table 1

Parameters used in the simulation

	Parameter	Value	Units
<i>DendriteLengthNGen1</i>	Dendrite length of the first <i>Self-oscillator</i> neuron (<i>Neuron1</i>)	0	-
<i>DendriteLengthNGen2</i>	Dendrite length of the second <i>Self-oscillator</i> neuron (<i>Neuron2</i>)	5	-
<i>NumExcSynapsesNGen1</i>	Number of excitatory synapses of the first <i>Self-oscillator</i> neuron (<i>Neuron1</i>). Should be ≥ 1 , since a single spike source (<i>Source</i> block) is always connected to the one of the synapses	2	-
<i>NumExcSynapsesNGen2</i>	Number of excitatory synapses of the second <i>Self-oscillator</i> neuron (<i>Neuron2</i>)	2	-
<i>NumInputDendrite</i>	Dendrites number of <i>Stimulus</i> neuron (<i>NeuronTrainer</i>), is equal to the dimensionality of an input pattern	4	-
<i>PatternFrequency</i>	Frequency of repeating the received spike by <i>PatternSource</i> block	500	Hz
<i>SpikesFrequency</i>	Firing frequency of <i>Stimulus</i> neuron	1,5	Hz

Fig. 4 shows the model's response to a change in the input pattern. The left arrow indicates the moment, when the input pattern was changed from [0; 0.03; 0.06; 0.09] (which is equal to the training sample) to [0.09; 0.06; 0.03; 0]. Since the new pattern differs significantly from the training example, the *NeuronTrainer* block stops responding (4). However, the *PatternSource* block is still maintaining the inhibitory effect for another time period equal to $T_{\text{PatternMode}}$ (5). After its expiry, the model begins to generate an alarm signal (left arrow) (6).

When the pattern is changed back to the original [0; 0.03; 0.06; 0.09] (right arrow), the signal stops.

The results of simulation confirm that the model copes with the main task, as it generates an alarm signal when the input pattern changes to an unfamiliar one.




Fig. 3. *NeuronTrainer* learning process




Fig. 4. The model's response to a change in the input pattern

Experiments. Binary classification task

The internal state control, at its simplest, is similar to the binary classification problem, since a distinction must be drawn between the normal state and an emergency situation. In this regard, the operation of proposed model was tested on a synthetic dataset, which consists of 50 measurements for class *A* (ordinary situation) and 100 measurements for class *B* (alarming situation). There are four values for each measurement in the set, which serves as features.

In a task of recognizing a spiking pattern, only the relative displacements of individual spikes in the pattern are significant. The displacement of the entire pattern along the time scale does not affect the recognition result in any way. However, in the task under consideration both relative and absolute values of spike times are significant, so it is necessary to tie the spiking pattern to some absolute value. To solve this problem, an additional calibration dendrite was added to the model. The value of time delay on this dendrite (the fifth element of an input pattern) is always set to the maximum value, i.e. equal to the width of the time window (in this study is equal to 0.2 s).

Thus, the input pattern in this experiment consisted of five spikes, so the number of dendrites on the trained neuron (the *NumInputDendrite* parameter of the *NeuronTrainer* block) was set to five. The values of other parameters correspond to those given in Table 1.




Fig. 5. Projection of the features space

The model was trained on one sample corresponding to the class *A* (ordinary situation). It was expected that the model would generate an alarm signal in response to a pattern corresponding to the class *B* (alarming situation) and would not respond to a pattern corresponding to the class *A* (ordinary situation).

As a result, the correct reaction was obtained in 99.3% of cases. Only one example out of 150 was classified incorrectly. Fig. 5 shows one of the six feature space projections of the used dataset (features 1 and 2). The white marker shows the training sample, the grey marker shows the sample, which was clas-

sified incorrectly by the model. It can be noted that for this sample the Euclidean distance value is the largest in the class.

Conclusion

The experiment results showed the possibility for the pain sensation model to be applied as a binary classifier or as a NOT logic gate. In the future, the proposed model can be used to implement behavioral functions, as well as a part of control mechanism in neuromorphic systems.

References

1. Melzack R., Wall P.D. Pain mechanisms: a new theory // *Science*. 1965. V. 150. No. 3699. P. 971–979.
2. Bakhshiev A., Gundelakh F. Mathematical Model of the Impulses Transformation Processes in Natural Neurons for Biologically Inspired Control Systems Development // *Supplementary Proceedings of the 4th International Conference on Analysis of Images, Social Networks and Texts (AIST-SUP 2015)*, Yekaterinburg, Russia, April 9–11, 2015. Published on CEUR-WS. 2015. V. 1452. P. 1–12.
3. Bakhshiev A., Fomin I., Gundelakh F., Demcheva A., Korsakov A. The architecture of a software platform for growing spiking neural networks simulator developing // *Journal of Physics: Conference Series* 1679. 2020.
4. Bakhshiev A.V., Korsakov A.M., Astapova L.A., Stankevich L.A. Strukturnaja adaptacija segmentnoj spajkovoj modeli nejrona // *Nelinejnaja dinamika v kognitivnyh issledovanijah – 2021. Trudy VII Vserossijskoj konferencii, Nizhnij Novgorod, 20–24 sentjabrja 2021 goda*. 2021. P. 30–33. (In Russian.)

А.А. КАПУСТНИКОВ, И.В. СЫСОЕВ, М.В. СЫСОЕВА

Саратовский филиал Института радиотехники и электроники
им. В.А. Котельникова РАН
anton.kapustnikov.02@mail.ru

МОДЕЛИРОВАНИЕ ЭПИЛЕПСИИ С ИСПОЛЬЗОВАНИЕМ СПЕЦИАЛИЗИРОВАННЫХ НЕЙРОНОВ РАЗНЫХ ТИПОВ*

В данной работе был продемонстрирован ансамбль из 14 связанных нейроосцилляторов для моделирования эпилепсии. В данном ансамбле присутствует 5 типов нейронов, для каждого из которых были выбраны соответствующие физиологические модели нейрона и физиологические параметры для них, кроме этого, из-за наличия возбуждающих и угнетающих связей в структуре связанных нейроосцилляторов, было принято решение использовать физиологические модели синапсов для AMPA и GABA рецепторов соответственно. В результате было показано, что подобная система способна демонстрировать длинные переходные процессы, моделирующие эпилептиформную активность, что является подтверждением гипотезы о ключевой роли структуры сети в возникновении разрядов при эпилепсии, а упор на физиологичность параметров и уравнений повышает научную значимость полученных результатов.

Ключевые слова: *временные ряды, эпилепсия, нейронная сеть, длинные переходные процессы.*

Введение

Как известно, эпилепсия является сетевым эффектом; влияние структуры сети является ключевым фактором в получении длинных переходных процессов [1], моделирующих эпилептиформную активность, что было продемонстрировано на 3-х моделях нейроосцилляторов: ФитцХью–Нагумо, Моррис–Лекара, Ходжкина–Хаксли. Следующим шагом было решение перейти к более физиологичным моделям как самих нейронов, так и синапсов для моделирования более физиологической синаптической связи между нейронами.

Исходя из того, что для моделирования эпилепсии необходимо учитывать наличие различных типов нейронов в сети, авторами было принято

* Работа выполнена при поддержке Российского научного фонда, грант 19-72-10030-Р (<https://rscf.ru/project/19-72-10030/>).

решение взять конкретные уравнения и параметры для каждого из типов нейронов, в основе которых лежала бы модель аксона большого кальмара (Ходжкина–Хаксли [2]). В данной работе присутствует 5 типов нейронов, для каждого из типов было найдено 5 моделей и физиологические параметры для каждой из них. Также из-за того, что ретикулярные нейроны (RE) и интернейроны (IN) оказывают угнетающее воздействие, имел место быть переход к моделированию синапсов: глутаматергических (AMPA) и ГАМК-ергических (GABA).

Модель

Рассмотрим модели для каждого типа нейрона по отдельности.

Для пирамидальных нейронов (PY) и интернейрона (IN) были взяты уравнения из [3], параметры для данных типов клеток брались из [4]. Для ретикулярных (RE) и таламо-кортикальных (TC) нейронов брались уравнения из [5–7], параметры [4]. Модель нейрона NT, моделирующего тройничный нерв, и параметры для него были взяты из [8]. Нейрон NT был выведен в постоянный колебательный режим.

Уравнения и параметры для моделирования синаптической связи брались из [4].

В данной работе рассматривалась матрица связности № 64 из класса матриц, представленного в [1], которая была способна демонстрировать более 10 остаточных колебаний (v – колебаний после прекращения стимуляции с NT-нейрона на систему) вне зависимости от вида модели нейро-осциллятора и типа функции связи между нейронами.

Величина коэффициента связи (k) между нейронами в данной сети была различна, значения представлены ниже (табл. 1).

Таблица 1

Величина коэффициента связи от вида нейронной связи

Ведущий нейрон / Ведомый нейрон	PY	TC	RE	IN	NT
PY	0,4675	14,76	0,4675	0,4675	–
TC	0,95	–	0,95	0,95	–
RE	–	–0,95	–0,95	–	–
IN	–0,95	–	–	–	–
NT	–	63,0	–	–	–

Результаты

В результате данная модель способна, как и в предыдущих работах, демонстрировать довольно длинные переходные процессы, как это видно из рис. 1 и рис. 2. Однако также видно, что v довольно сильно отличается для каждого нейрона, к тому же некоторые нейроны и вовсе не показывают колебательную активность. Это может объясняться следующим образом.




Рис. 1. Временные ряды всех узлов матрицы № 64. Черные линии указывают на начало и завершение внешнего подключения от NT к узлу TC1

Во-первых, структурой сети, поскольку на некоторых матрицах, которые присутствуют в рассматриваемом классе, часть молчащих нейронов запускается. Во-вторых, для каждого типа нейронов используются индивидуальные уравнения и параметры, что также может влиять на то, сколько остаточных колебаний показывает каждый тип, например в данной модели РУ-клетки очень чувствительны и их очень легко возбудить и перевести в колебательный режим. В-третьих, по всей видимости, модель таламо-кортикальной системы, состоящая из 14 нейронов, слишком мала; также было высказано мнение, что при переходе к использованию разных моделей для каждого типа клеток в сети необходимо переходить к более большим сетям, где количество нейронов и связей между ними будет достаточно велико.

Несмотря на это, большая часть нейронов сети возбудилась от воздействия NT-нейрона и показала довольно большое количество остаточных колебаний, что, в свою очередь, ещё больше подтверждает гипотезу о том, что уравнения для нейронов и синапсов играют второстепенную роль.




Рис. 2. Количество остаточных колебаний (v) для каждого нейрона матрицы № 64

Выводы

Продемонстрирована модель эпилепсии, моделирующая эпилептиформную активность после возбуждения системы, пришедшего от тройничного нерва. В данной модели матрицы связности составлены в соответствии с анатомическими законами; продемонстрированы длинные переходные процессы, которые возникают за счет исследованных в [1] механизмов; каждый тип нейронов и синапсов описывается своим уравнением и имеет физиологические параметры (что повышает научную ценность данной модели).

Список литературы

1. Kapustnikov A.A., Sysoeva M.V., Sysoev I.V. Transient dynamics in a class of mathematical models of epileptic seizures // Communications in Nonlinear Science and Numerical Simulation. 2022. V. 109. P. 106284.
2. Hodgkin A., Huxley A. A quantitative description of membrane current and its application to conduction and excitation in nerve // J. Physiol. 1952. V. 117, N 4. P. 500–544.
3. McCarthy M.M., Brown E.N., Kopel N. Potential network mechanisms mediating electroencephalographic beta rhythm changes during propofol-induced paradoxical excitation // Journal of Neuroscience. 2008. V. 28, N 50. P. 13488–13504.
4. Ching S., Cimenser A., Purdon P.L., Brown E.N., Kopell N.J. Thalamocortical

- model for a propofol-induced α -rhythm associated with loss of consciousness // Proceedings of the National Academy of Sciences. 2010. V. 107, N 52. P. 22665–22670.
5. Destexhe A., McCormick D.A., Sejnowski T.J. A model for 8–10 Hz spindling in interconnected thalamic relay and reticularis neurons // Biophysical Journal. 1993. V. 65, N 6. P. 2473–2477.
 6. Destexhe A., Bal T., McCormick D.A., Sejnowski T.J. Ionic mechanisms underlying synchronized oscillations and propagating waves in a model of ferret thalamic slices. Journal of Neurophysiology. 1996. V. 76, N 3. P. 2049–2070.
 7. Destexhe A., Sejnowski T.J. Thalamocortical Assemblies: How Ion Channels, Single Neurons and Large-Scale Networks Organize Sleep Oscillations. New York : Oxford University Press, 2001.
 8. Wu N., Enomoto A., Tanaka S., Hsiao C.F., Nykamp D.Q., Izhikevich E., [et al.] Persistent Sodium Currents in Mesencephalic V Neurons Participate in Burst Generation and Control of Membrane Excitability // Journal of Neurophysiology. 2005. V. 93, N 5. P. 2710–2722.

**А.В. ПОЛЕВАЯ, С.А. ПОЛЕВАЯ, А.Ю. ПЕТУХОВ,
И.В. ЛОСКОТ, С.Б. ПАРИН**

Нижегородский государственный университет им. Н.И. Лобачевского
loskot@fsn.unn.ru

**ЭКСПЕРИМЕНТАЛЬНАЯ ДИАГНОСТИКА
ЭМОЦИОНАЛЬНОГО СОСТОЯНИЯ ИНДИВИДОВ
С ИСПОЛЬЗОВАНИЕМ АФФЕКТИВНЫХ
АУДИОВИЗУАЛЬНЫХ СТИМУЛОВ***

Решается задача объективной диагностики эмоционального состояния индивидов при воздействии внешних аудиовизуальных стимулов. Предложены, реализованы и исследуются экспериментальные методики, основанные на анализе динамики variability сердечного ритма (BCP) в зависимости от эмоциональной валентности (положительная, отрицательная) и модальности стимула (звук, изображение) с использованием инструментов телеметрии сердца. В рамках исследования проводилась оценка уровня эмоциональной дезадаптации индивида и самодиагностика эмоциональной реакции методикой SAM. Новизна работы заключается в оценке степени влияния аудиовизуальных стимулов с учетом конфликта их валентности или модальности. По результатам исследования выявлены особенности воздействия аудиовизуальных стимулов, на основе которых возможна диагностика эмоционального состояния индивида в контексте внешней информационной среды.

Ключевые слова: *эмоциональное состояние, диагностика, информационные образы, информационная репрезентация, телеметрия ритма сердца, BCP, УЭД, SAM.*

Введение

Информационная среда с каждым годом все более и более способствует повышению уровня стресса. Этому способствуют не только внешние факторы (пандемия, войны), но также интеграция человека во множество информационных сред и возросшее количество внешних стимулов. Проблема точной и удобной оценки влияния информационной среды на индивида и диагностики его состояния становится, как никогда, актуальной.

Разработано множество инструментов определения эмоционального

* Данная работа выполнена при частичной поддержке РФ, грант № 22-18-20075.

состояния, например опросник SAM (Self-Assessment Manikin) [1]. Благодаря этому связываются объективные физиологические показатели с субъективной оценкой собственного состояния индивидом. В качестве стимульного материала в подобных исследованиях используются изображения, звуковые стимулы [1–3].

Человек мыслит не на основе кода, подобно компьютеру, а на основе взаимодействующих многочисленных образов (репрезентаций). Данные образы хотя и имеют в основе своего функционирования вполне конкретную материальную структуру (электрическая и химическая активность в головном мозге человека), но при этом их описание обычными математическими моделями затруднено по ряду причин [4–5]. Для разработки схемы эксперимента необходимо предложить обоснование воздействия информационных образов на индивида. В данной статье предлагается описание активности информационных образов на основе математического аппарата квантовой физики [6].

Методические и теоретические основы эксперимента

В качестве основного метода был выбран анализ variability сердечного ритма (BCP). Показатели BCP отображают тонус вегетативной системы, ее симпатического и парасимпатического отделов, что позволяет оценить психоэмоциональное состояние человека в динамике [1, 7]. Для регистрации физиологических сигналов использовалась технология событийно-связанной телеметрии ритма сердца, что позволило минимизировать влияние на естественное состояние испытуемого без ущерба точности получаемых данных (принцип амбиентности) [11, 17].

В актуальных исследованиях эмоций большинством исследователей в качестве стимульного материала применяются нормативные базы IAPS и IADS. Для невербальной самооценки эмоционального воздействия стимулов здесь предложено использовать опросник Self-Assessment Manikin (SAM). Преимущество методики заключается в простоте и ясности ее использования для всех испытуемых [8, 10–12].

В основе предлагаемого исследования лежит теория информационных репрезентаций (ТИР). ТИР дает альтернативный взгляд на некоторые характерные закономерности в человеческом сознании, позволяя правильно интерпретировать и объяснять некоторые из них. Взаимодействие двух индивидуумов представлено как взаимодействие двух систем с помощью КП в информационной среде. Также представляет интерес влияние на одного человека той или иной информационной среды (например, СМИ, интернет-ресурсов, социальной среды и т. д.) [5].

Экспериментальная модель оценки когнитивных проявлений аффективных стимулов

В исследовании приняли участие 67 человек в возрасте от 17 до 56 лет (48 женщин и 19 мужчин). Все испытуемые являлись условно здоровыми, без выявленных сердечно-сосудистых заболеваний и психологических отклонений. Участники предварительно подписали информационное согласие на участие в исследовании.

В качестве стимульного материала было отобрано 24 аудиозаписи:

1. 12 позитивных, т.е. с наивысшими средними значениями по шкале «валентность» в диапазоне от 2,33 до 2,9.
2. 12 негативных, т.е. со средними значениями по шкале «валентность» в диапазоне от -3,43 до -2,96.

Стимульный материал аффективных изображений включал 24 фотографии:

1. 12 позитивных, т.е. с наивысшими средними значениями по шкале «валентность» в диапазоне от 2 до 4.
2. 12 негативных, т.е. со средними значениями по шкале «валентность» в диапазоне от -4 до -2.

Было решено сформировать 2 набора стимулов:

1. Базовый, с последовательно выстроенными к предъявлению негативным и позитивным аудиовизуальными стимульными наборами в форме единого видео.
2. Диссонансный, с последовательно выстроенными к предъявлению отрицательными изображениями и положительными звуками, затем с положительными изображениями и отрицательными звуками, в форме единого видео.

До начала исследования испытуемым надевался датчик событийно-связной телеметрии для сбора данных ВСР на протяжении всего эксперимента. Для целей калибровки проводилось две ортопробы (3 минуты каждая) в состоянии покоя сидя и стоя. Далее, испытуемым предъявлялся базовый или диссонансный набор. Испытуемым предлагалось оценить валентность с помощью методики SAM. Также испытуемые проходили мониторинг уровня эмоциональной дезадаптации (УЭД). Исследование длилось 24 минуты.

Процедура эксперимента схематично представлена на рис. 1.




Рис. 1. Схема исследования с ритмограммой

Результаты

В ходе сравнения стимулов разной валентности и одной модальности были найдены достоверные различия (табл. 1).

Таблица 1

Достоверные различающиеся вариации сравнения блоков исследования с помощью парного теста по W-критерию Уилкоксона

Пары сравнения	Valid	T	Z	p-value
Sbad+Pbad & Sbad+Pgood	11	3.00	2.67	0.01
Sbad+Pbad & Sgood+Pbad	21	9.00	3.70	0.00
Sbad+Pbad & Sgood+Pgood	13	9.00	2.55	0.01
Sbad+Pbad & PBad	11	0.00	2.93	0.00
Sbad+Pbad & SBad	12	10.50	2.24	0.03
Sbad+Pbad & Pgood	15	0.00	3.41	0.00
Sbad+Pbad & Sgood	15	0.00	3.41	0.00
Sbad+Pgood & Sgood+Pbad	15	4.00	3.18	0.00
Sbad+Pgood & PGood	13	2.00	3.04	0.00
Sbad+Pgood & SGood	14	1.50	3.20	0.00
Sgood+Pbad & Sgood+Pgood	14	4.50	3.01	0.00
Sgood+Pbad & PBad	15	2.00	3.29	0.00
Sgood+Pbad & SBad	15	1.00	3.35	0.00
Sgood+Pgood & PGood	13	7.50	2.66	0.01
Sgood+Pgood & SGood	13	0.00	3.18	0.00
PBad & PGood	14	2.00	3.17	0.00
PBad & SGood	15	3.00	3.24	0.00
SBad & PGood	15	0.00	3.41	0.00
SBad & SGood	14	0.00	3.30	0.00

При сравнении средних значений валентности диссонансного комплекса отмечается склонность испытуемых к негативной оценке. Таким

образом, присутствие негативного аудиальной или визуальной ИР склоняет субъективную оценку среды индивидом в негативную сторону различия (рис. 2, 3) (табл. 2).




Рис. 2. Сравнение средних значений валентности диссонансного комплекса; специальным символом «*» обозначены достоверные различия между соответствующими блоками по W-критерию Уилкоксона ($p < 0.05$)




Рис. 3. Сравнение средних значений валентности базового и диссонансного комплексов; специальным символом «*» обозначены достоверные различия между Sbad+Pbad и Sbad+Pgood по W-критерию Уилкоксона ($p < 0.05$); специальным символом «Δ» обозначены достоверные различия между Sbad+Pbad и Sgood+Pgood по W-критерию Уилкоксона ($p < 0.05$)

Таблица 2

Средние значения и стандартные ошибки средних оценок Валентности по стимулам из базового и диссонансного комплексов

СТИМУЛ	валентность образа		
Sbad+Pbad	-2.27	±	0.38
Sbad+Pgood	-1.20	±	0.49
Sgood+Pgood	1.45	±	0.36
Sgood+Pbad	-1.20	±	0.49

Во время эксперимента имелась слабо выраженная дезадаптация: после негативной стимуляции произошел рост значений УЭД, после позитивной – значения пришли в исходное состояние (рис. 4, 5).




Рис. 4. Сравнение значений УЭД для базового комплекса; получены достоверные различия по W-критерию Уилкоксона ($p < 0.05$)




Рис. 5. Сравнение значений УЭД до и после негативной и позитивной стимуляции ($p < 0.05$)

Функциональное состояние испытуемых оценивалось по данным ВСП. Процент редактирования записей составил меньше 5%, что говорит о хорошем качестве полученных данных.

По оценкам SAM, шкала «валентность», 67% испытуемых имело стандартные оценки, 33% – нестандартные: позитивные и негативные стимулы оценивались испытуемыми как нейтральные, либо позитивные стимулы оценивались как негативные.

Для каждого испытуемого был рассчитан индекс оптимизации состояния, рассчитанный на основе спектральных характеристик ВСП (табл. 3).

Таблица 3

Маркеры оптимизации состояния в зависимости от функционального эффекта

Увеличение адаптационного потенциала	↑ Общая мощность спектра вариабельности (TP)	↑ Функциональный резерв (FR)	↑ Высокочастотный спектр (HF)	↑ RR-интервалы (RR)
Снижение напряжения регуляторных систем	↓ Индекс вегетативного баланса (LF/HF)	↓ Индекс стресса (SI)	↓ Степень напряжения (SN)	↓ Низкочастотный спектр (LF)

Выводы и обсуждение

Выявлено, что добавление позитивных визуальных ИР в виде изображений достоверно влияет на эмоциональное восприятие звуковых ИР.

Варианты причин такого эффекта:

1. Модуль одной эмоциональной системы гасит эффект другой.

Образец воздействует на одну эмоциональную компоненту, освобождая ее от другой модальности. Они взаимодействуют друг с другом, и в какой-то момент признак модальности отходит в сторону, и они взаимодействуют друг с другом, что может являться следствием работы лимбической системы.

2. Шум затрудняет распознавание стимулов, трудно выделить эмоциональный образ.

Интерференция ИР проявляется в редукции эмоций при воздействии ИР разной валентности инвариантно к зрительной или звуковой модальности стимула. При этом показано, что объединение стимулов негативной валентности ведёт к усилению эмоциональной реакции, в то время как для позитивных стимулов подобного эффекта не наблюдается.

Для диссонансного набора негативный аудиальный стимул вызывает рост уровня дезадаптации; негативный визуальный стимул не дает такого эффекта.

Таким образом, на основе ТИР авторами был разработан методический комплекс, который позволяет получить объективную и субъективную оценки эмоционального аффекта индивида при воздействии аудиовизуальных ИР.

Список литературы

1. Васанов А.Ю., Марченко О.П., Севостьянова М.С. Подбор культурноспецифических эмоционально окрашенных фотоизображений для экспериментальных исследований // Экспериментальная психология. 2013. Т. 6, № 4. С. 105–114.
2. Козачук И.В., Кириллова И.А., Ведерникова Т.Н., Симонов С.Н. Эффекты аудиостимуляции в виде звуков природы на регуляцию сердечного ритма // Вестник ТГУ. 2012. Т. 17, № 4. С. 1270–1272.
3. Choi K.-H., Kim J., Kwon O. [et al.]. Is heart rate variability (HRV) an adequate tool for evaluating human emotions? A focus on the use of the International Affective Picture System (IAPS) // Psychiatry Research. 2017. V. 251. P. 192–196.
4. Анохин К.В. Генные зонды для картирования нервных сетей при обучении. Принципы и механизмы деятельности мозга человека. Л.: Наука. 1989.
5. Petukhov A.Y., Polevaya S.A. Modeling of cognitive brain activity through the Information Images Theory in terms of the bilingual Stroop test // International Journal of Biomathematics. 2017. V. 10, N 6. P. 1750092.
6. Физика микромира. Москва : Наука. 1980.
7. Ковалева А.В., Панова Е.Н., Горбачева А.К. Анализ variability ритма сердца и возможности его применения // Современная зарубежная психология. 2013. № 1. С. 35–50.
8. Yun H., Fortenbacher A., Pinkwart N., Bisson T., Moukayed F. A Pilot Study of Emotion Detection using Sensors in a Learning Context: Towards an Affective Learning Companion // Proceedings of DeLFI and GMW Workshops. 2017. V. 2092. P. 54–65.
9. Полевая С.А., Парин С.Б., Еремин Е.В., Буланов Н.А., Чернова М.А. Разработка технологии событийно-связанной телеметрии для исследования когнитивных функций // XVIII Международная научно-техническая конференция «Нейроинформатика-2016» : Сборник научных трудов. Москва : НИЯУ МИФИ. 2016. Ч. 1. С. 34–44.
10. Bradley M. M., Lang P. J. The International Affective Digitized Sounds (2-nd Edition; IADS-2): Affective Ratings of Sounds and Instruction Manual Gainesville, FL: The Center for Research in Psychophysiology, University of Florida. 2007. P. 29–46.
11. Lang P.J., Bradley M.M., Cuthbert B.N. International affective picture system (IAPS): Instruction manual and affective ratings. Technical Report A-4. Gainesville, FL: The Center for Research in Psychophysiology, University of Florida. 1999.
12. Косоногов В.В., Мартинес-Сельва Х.М., Санчес-Наварро Х.П. Обзор современных методов измерения физиологических признаков знака и силы эмоциональных состояний // Теоретическая и экспериментальная психология. 2017. Т. 10, № 3. С. 63–78.
13. Рунова Е.В., Григорьева В.Н., Бахчина А.В., Парин С.Б., Шишалов И.С., Кожевников В.В., Некрасова М.М., Каратушина Д.И., Григорьева К.А., Полевая С.А. Вегетативные корреляты произвольных отображений эмоционального стресса // СТМ. 2013. Т. 5, № 4. С. 69–77.

М.М. ПУГАВКО, О.В. МАСЛЕННИКОВ, В.И. НЕКОРКИН

Федеральный исследовательский центр Институт прикладной физики РАН,
Нижний Новгород

Нижегородский государственный университет им. Н.И. Лобачевского
slavapugavko2@gmail.com, olmaov@ipfran.ru, vnekorkin@ipfran.ru

ДИНАМИКА РЕКУРРЕНТНОЙ СПАЙКОВОЙ НЕЙРОННОЙ СЕТИ ПРИ РЕШЕНИИ НЕСКОЛЬКИХ ЗАДАЧ КОГНИТИВНОЙ НЕЙРОНАУКИ*

В работе представлена рекуррентная спайковая нейронная сеть, которая методами машинного обучения обучена решать несколько различных целевых задач, инспирированных экспериментами в области когнитивной нейронауки. Изучены динамические механизмы выполнения сетью целевых функций, состоящие в появлении определенных траекторий в пространстве популяционной активности нейронов. Выявлена иерархическая структура сети после обучения, в которой имеются подгруппы нейронов как специализированные относительно решения каждого типа задач, так и со смешанной селективностью, демонстрирующие активность при выполнении различных функций.

Ключевые слова: *спайковая нейронная сеть, нелинейная динамика, машинное обучение, когнитивная нейронаука.*

Введение

Одним из важных направлений на стыке вычислительной и когнитивной нейронауки, с одной стороны, и систем искусственного интеллекта, с другой, является построение и анализ функциональных искусственных нейронных сетей (ИНС) [1, 2]. В качестве целевых задач для таких систем выбираются функции преобразования входных стимулов в выходные, имеющие своим прототипом эксперименты в области когнитивной нейронауки. В данном классе экспериментов испытуемое животное на основе анализа сенсорных (например, зрительных) стимулов принимает решение, выраженное определенной двигательной активностью. Одновременный электрофизиологический анализ активности клеток мозга позволяет сопоставить внешние переменные эксперимента (параметры стимулов и откликов) с динамикой нейронов. Понимание причинно-следственных свя-

* Данная работа выполнена при поддержке гранта РНФ № 21-72-00142.

зей между нейрональной активностью и поведением на основе лишь экспериментальных данных по ряду причин затруднительно. Поэтому в настоящее время для данных целей активно развивается подход на основе функциональных ИНС, при построении которых могут накладываться биологически мотивированные условия. Настроенная методами машинного обучения нейросеть выполняет целевую задачу, которая, как правило, является редуцированной версией экспериментальной. В то же время данная сеть является динамической системой и может быть исследована методами нелинейной динамики и теории сетей на предмет выявления динамических и структурных механизмов выполнения целевых функций [3–5]. Большинство предложенных моделей в указанном направлении, с одной стороны, реализованы для выполнения единственной целевой задачи. С другой стороны, базовым элементом таких нейросетей служат нелинейные функции активации, не учитывающие ключевую особенность реальных нейронов коммуницировать посредством потенциалов действия или спайков. В настоящей работе предложена рекуррентная спайковая нейронная сеть, в которой динамика элементов описывается моделью адаптивного экспоненциального нейрона. Методами машинного обучения сеть настроена выполнять целый ряд модельных задач когнитивной нейронауки. Исследованы траектории в пространстве активности нейросети, лежащие в основе решения данных задач. Выявлены закономерности иерархической кластеризации обученной сети, при которой нейроны объединяются в группы со своей особой ролью в выполнении целевых функций.

Модель сети

Общая архитектура спайковой искусственной нейронной сети, которая использовалась в работе, показана на рис. 1. Сеть состоит из $N = 256$ связанных спайковых нейронов, топология связей между которыми задается матрицей $W^{rec} \in \mathbb{R}^{N \times N}$. Изначально сеть инициализируется таким образом, чтобы каждый нейрон был связан со всеми остальными, а элементы матрицы определяются нормальным распределением $\sqrt{2/N} \mathcal{N}(0, 1)$. Входы сети можно разделить на три разные по смыслу части. Первая часть – это скалярный сигнал фиксации, разделяющий различные фазы испытания. Он равен единице при получении сетью стимулов и становится равным нулю, когда сеть должна сгенерировать на выходе отклик. Следующая часть – это содержательные сигналы в виде двумерного вектора, компоненты которого моделируют сенсорные стимулы двух различных модаль-

ностей [6]. Третья часть – вектор, кодирующий тип задачи, в котором только один элемент равен единице, остальные нулевые. Вектор входов определяется следующим образом:

$$\mathbf{u} = (u_{fix}, \mathbf{u}_{mod}, \mathbf{u}_{tasks})^T, \quad (1)$$

где $u_{fix} \in \mathbb{R}^1$ – сигнал фиксации, $\mathbf{u}_{mod} = (u_{mod_1}, u_{mod_2})$ – входные стимулы, $\mathbf{u}_{tasks} = (u_{task_1}, u_{task_2}, \dots, u_{task_{N_{task}}})^T$ – вектор задач с единственным ненулевым элементом, индекс которого равен номеру выполняемой в текущем испытании задачи, $N_{in} = N_{task} + 3$ – общее количество входов.




Рис. 1. Схематичное представление сети

Динамика сети описывается следующим образом:

$$\begin{cases} I_j^{in}(n+1) = \sum_{i=1}^{N_{in}} w_{ji}^{in} u_i(n+1), \\ I_j^{rec}(n+1) = \sum_{l=1}^N w_{jl}^{rec} z_l(n), \\ v_j(n+1) = v_j(n) + \frac{\Delta t}{\tau_m} (-v_j(n) + \theta \exp(\frac{v_j(n) - v_{th}}{\theta}) + I_j(n) - a_j(n)), \\ I_j(n+1) = I_j(n)(1 + \frac{\Delta t}{\tau_s}) + I_j^{rec}(n+1) + I_j^{in}(n+1), \\ a_j(n+1) = a_j(n) + \frac{\Delta t}{\tau_a} (a_j^{current} v_j(n) - a_j(n)), \end{cases} \quad (2)$$

где Δt – шаг симуляции, который равен 1 мс во всей работе, W_{ij}^{in} – элемент матрицы входных весов, W_{ij}^{rec} – элемент матрицы связей между нейронами, $n \in \mathbb{Z}$ – дискретное время. Выходы сети определяются системой

$$y_j(n+1) = \kappa y_j(n) + \sum_{i=1}^N W_{ji}^{out} z_i(n) + b_j^{out}, \quad (3)$$

где $\kappa = \exp(-\Delta t / \tau_{out})$ – параметр фильтра с константой времени $\tau_{out} = 50 \text{ мс}$, $z(n) = H(v(n) - v_{th})$ – спайковая переменная. При достижении мембранного потенциала значения v_{th} происходит сброс мембранного потенциала на значение v_{reset} и увеличение адаптационной переменной $a \rightarrow a + a_s$. Все параметры сети представлены в табл. 1.

На рис. 2. представлена динамика отдельного нейрона, а именно активность адаптационной переменной (а), мембранного потенциала (в) и результирующих спайков (г) при действии входного тока (б).




Рис. 2. Пример динамики одного нейрона при наличии входного воздействия

Данная модель является биологически правдоподобной версией модельного нейрона накопление-сброс, и, как установлено в данной работе, наличие как быстрой, так и медленной переменной способствует более качественному решению целевых задач с рабочей памятью.

Таблица 1

Параметры сети

Обозначение	Значение	Размерность
τ_a	2	с
τ_m	10	мс
τ_s	5	мс
V_{th}	0,45	мВ
V_{reset}	0	мВ
θ	0,5	мВ
a_s	0,02	мА
$a_{current}$	4	нс

Целевые задачи

В работе рассмотрено 6 типов задач. Первый тип задачи (рис. 3а, ж), который будем обозначать "DM", основан на эксперименте [7], суть которого состоит в принятии решения (decision making – DM) испытуемым в результате двухальтернативного выбора. В модели сеть должна сравнивать с пороговым значением (0.5) зашумленный входной стимул. Если среднее значение стимула за время испытания ниже порога, то генерируется отклик на первом выходе, а если выше порога, то на втором. Второй тип задачи ("CtxDM") – контекстно-зависимое принятие решения – основан на работе [8]. Ключевое отличие от предыдущей задачи – сеть производит сравнение стимулов определенной модальности и игнорирует стимулы другой, что контролируется сигналом контекста (рис. 3б, з). Третий, четвертый и пятый типы задач, обозначаемые соответственно "Go" (рис. 3в, и), "GoDI" (рис. 3г, й), "GoRt". (рис. 3д, к), основаны на работах [9, 10, 11] и представляют собой появление определенной выходной реакции сети в ответ на входной стимул. Шестой тип задач ("Romo", по имени ключевого исполнителя экспериментальной работы) основан на работе [12] и заключается в сравнении двух стимулов, подаваемые на вход через интервал задержки. Параметры всех задач приведены в табл. 2.

Таблица 2

Параметры задач

Задача	Время подачи стимула или время фазы фиксации, мс	Задержка между стимулами, мс	Время фазы отклика, мс	Значение входного стимула
DM	$\sim U(300, 1800)$	–	250	$\sim U(0, 1)$

CtxDM		—		$\sim U(\{0, 1/7, 2/7, ..., 1\})$
Go		—		
GoRt		—		
GoDl		$\sim U(200, 600)$	1500	
Romo		$\sim U(200, 1700)$	250	$\sim U(0, 1)$




Рис. 3. Входы и целевые выходы. Пунктирной линией отображен сигнал фиксации. Линия точка-тире обозначает порог для задач DM и CtxDM. Черная линия обозначает первый выход или вход, серая линия обозначает второй выход или вход

Метод обучения

Для построения и обучения сети в данной работе использована библиотека "Norse" [13]. В качестве метода обучения выбран метод обратного распространения во времени (BPTT). Для этого определяется функция потерь следующим образом:

$$E = MSE + \lambda E_r, \tag{4}$$

где среднеквадратичное отклонение между реальным выходом сети и целевым определяется

$$MSE = \frac{1}{N_{out} N_{batch} N_{step}} \sum_{i=1}^{N_{out}} \sum_{l=1}^{N_{batch}} \sum_{n=1}^{N_{step}} m_{il}(n)(y_{il}(n) - \hat{y}_{il}(n))^2, \quad (5)$$

и регуляризацией по средней частоте

$$E_r = \sum_{i=1}^N f_i H(f_i - f_{th}), \quad (6)$$

где порог частоты установлен на 30 герц. Средняя частота определяется следующим образом:

$$f_i = \frac{1}{N_{batch} N_{time}} \sum_{l=1}^{N_{batch}} \sum_{n=1}^{N_{time}} z_{il}(n). \quad (7)$$

Метод обучения модифицирован на основе метода оптимизации весовых коэффициентов "Adam" со скоростью обучения 0,005 и со стандартными коэффициентами для расчета скользящих средних градиента и его квадрата 0,9 и 0,999. Параметр регуляризации $\lambda = 10^4$. Кроме того, наличие спайковой динамики приводит к необходимости ввести так называемую *псевдопроизводную* в методе "superspike" [14] для переменной z в виде

$$\sigma'_j = (1 + |\alpha(v_j(n) - v_{th})|)^{-2}, \quad (8)$$

где $\alpha = 100$. Подробности такой замены см. в [14].

Популяционная динамика

Спайковую нейронную сеть (2) можно рассматривать как многомерную динамическую систему. С помощью метода главных компонент найдены проекции высокоразмерной популяционной активности на подпространства, в которых максимизирована дисперсия данных для переменной a и для мембранного потенциала. Проекции в пространство трех главных компонент во время выполнения задачи ДМ отображены на рис. 4а, б. Данные два графика демонстрируют разделение траекторий на два потока, которые соответствуют двум категориям решения задачи. Излом траекторий обозначает отключение входного стимула и сигнала фиксации и переход к фазе отклика.

Проекции в пространство трех главных компонент во время решения задачи Ромо отображены на рис. 4в, г. Данные два графика демонстрируют снова разделение на две задачи. Стоит отметить, что данная задача требует от сети запоминать первый стимул, что соответствует метастабильному состоянию в пространстве главных компонент. В начале каждого испытания на вход подается стимул с определенным значением. Далее наступает период задержки, который на графике рис. 4г соответствует

гладкой и протяженной траектории. После этого подается второй короткий стимул. После этого происходит отключение сигнала фиксации и траектории быстро смещаются, что соответствует принятию решения.

Анализ остальных задачи CtxDM, Go, GoDl и GoRt выявил механизмы их реализации на популяционном уровне, основная суть которых состоит в разделении траекторий на отдельные выраженные потоки в зависимости от характеристик входных стимулов.




Рис. 4. Проекция в пространство трех главных компонент для задачи DM (а, б) и Romo (в, г). На графиках (а) и (в) отображены проекции для переменной v , а на графиках (б) и (г) отображены проекции для переменной a

Специализация нейронов

В процессе обучения происходит перестройка весовых коэффициентов, что приводит к появлению подгрупп нейронов, по-разному специализированных при выполнении различных типов задач. На рис. 5 показана дендрограмма, которая получена с помощью классического подхода иерархи-

ческой кластеризации с применением метода Уорда. В левой части графика расположена подгруппа нейронов с наибольшей смешанной селективностью, которые активны достаточно сильно во время выполнения всех задач. В центре находятся подгруппы нейронов, которые слабо активны, и их активность распределена достаточно равномерно по задачам. В правой части графика выделяются нейроны, которые специализируются на конкретных задачах.




Рис. 5. Дендрограмма и разбиение сети на кластеры после обучения. Оттенком серого отображается нормализованная средняя частота каждого нейрона во время выполнения каждой задачи. Усреднение производилось по 100 испытаниям каждой задачи

Заключение

В работе исследованы механизмы решения различных когнитивных задач искусственной спайковой нейронной сетью, которая обучена на основе методов машинного обучения. Проанализированы траектории в пространстве активности сети для каждой когнитивной задачи, установлены динамические механизмы решения каждой задачи. Проанализировано разбиение нейросети на подгруппы с различной ролью при решении определенных задач.

Список литературы

1. Maslennikov O.V., Pugavko M.M., Shchapin D.S., Nekorkin V.I. (2022). Nonlinear dynamics and machine learning of recurrent spiking neural networks. *Phys. Usp.* Accepted.
2. Richards B.A., Lillicrap T.P., Beaudoin, P., Bengio Y., Bogacz R., Christensen A., Clopath C., Costa R.P., de Berker A., Ganguli S., Gillon C.J. A deep learning framework for neuroscience // *Nature neuroscience*. 2019. V. 22, N 11. P.1761–1770.
3. Maslennikov O.V., Nekorkin V.I. Stimulus-induced sequential activity in supervised recurrent networks of firing rate neurons // *Nonlinear Dynamics*. 2020. V. 101, N 2. P. 1093–1103.
4. Pugavko M.M., Maslennikov O. V., Nekorkin V.I. Dynamics of spiking map-based neural networks in problems of supervised learning // *Communications in Nonlinear Science and Numerical Simulation*. 2020. V. 90. P. 105399.
5. Vyas S., Golub M.D., Sussillo D., Shenoy K.V. Computation through neural population dynamics // *Annual Review of Neuroscience*. 2020. V. 43. P. 249–275.
6. Yang G.R., Joglekar M.R., Song H.F., Newsome W.T., Wang X.-J. Task representations in neural networks trained to perform many cognitive tasks // *Nature neuroscience*. 2019. V. 22, N 2. P. 297–306.
7. Britten K.H., Shadlen M.N., Newsome W.T., Movshon J.A. The analysis of visual motion: a comparison of neuronal and psychophysical performance // *Journal of Neuroscience*. 1992. V. 12, N 12. P. 4745–4765.
8. Mante V., Sussillo D., Shenoy K.V., Newsome W.T. Context-dependent computation by recurrent dynamics in prefrontal cortex // *Nature*. 2013. V. 503, N 7474. P. 78–84.
9. Funahashi S., Bruce C.J., Goldman-Rakic P.S. Mnemonic coding of visual space in the monkey's dorsolateral prefrontal cortex // *Journal of neurophysiology*. 1989. V. 61, N 2. P. 331–349.
10. Brücke C., Kempf F., Kupsch A., Kühn A.A., Schneider G.H., Krauss J.K., Aziz T., Yarrow K., Pogosyan A., Brown P. Movement-related synchronization of gamma activity is lateralized in patients with dystonia // *European Journal of Neuroscience*. 2008. V. 27, N 9. P. 2322–2329.

11. Brücke C., Bock A., Huebl J., Schönecker T., Kühn A.A., Schneider G.-H., Krauss J.K., Brown P. Thalamic gamma oscillations correlate with reaction time in a go/nogo task in patients with essential tremor // *Neuroimage*. 2013. V. 75. P. 36–45.
12. Romo R., Brody C.D., Hernández A., Lemus L. Neuronal correlates of parametric working memory in the prefrontal cortex // *Nature*. 1999. V. 399. P. 470–473.
13. Pehle C., Pedersen J.E. Norse – A deep learning library for spiking neural networks, documentation: <https://norse.ai/docs/>
14. Zenke F., Ganguli S. Superspike: Supervised learning in multilayer spiking neural networks // *Neural computation*. 2018. V. 30, N 6. P. 1514–1541.

А.В. САМСОНОВИЧ

Национальный исследовательский ядерный университет «МИФИ», Москва
avsamsonovich@mephi.ru

**О ВОЗМОЖНОСТИ ОПРЕДЕЛЕНИЯ ПСИХОЛОГИЧЕСКИХ
ХАРАКТЕРИСТИК ЛИЧНОСТИ ПОЛЬЗОВАТЕЛЯ ПРИ ЕГО
РУТИННОМ ВЗАИМОДЕЙСТВИИ С АРТЕФАКТОВ**

Рассматривается задача предсказания результатов психологического теста «большой пятерки» на основе данных о поведении пользователя в рутинном процессе виртуальной регистрации в отель. Участники эксперимента вели диалог с воображаемым виртуальным агентом – Регистратором. Данные о поведении участников позволили с разумной точностью предсказать две из пяти характеристик их типа личности. Полученный результат позволяет предложить концепцию «Психометра» на основе виртуального агента или робота, способного незаметно определять психологические характеристики клиентов в процессе выполнения своей основной задачи без использования дополнительных средств. Метод также может быть использован для оценки поведения искусственных социальных агентов.

Ключевые слова: *психологическое профилирование, социальные агенты, психометрия, эмоциональный интеллект, метрики человекоподобия.*

Введение

Для определения психологического типа личности сегодня, как правило, используют стандартные опросники: тесты Кетелла (16PF) [1], Бойко [2], Мехрабиана [3] и другие. Самый известный из них – тест «большой пятерки» [4–6], существующий в нескольких разновидностях: OCEAN, 5PFQ, последний также используется в адаптации для русскоязычных испытуемых [7]. Известно, что при должном прохождении теста его результаты характеризуют личность данного человека и мало зависят от других факторов. Поэтому данная процедура используется для психологической и клинической диагностики [8], для оценки кандидата при приеме на работу и в других ситуациях, когда требуется составить по возможности объективный психологический портрет незнакомого человека.

* Данная работа выполнена при поддержке РФФИ, грант № 22-11-00213.

Иметь подобную информацию было бы полезно во многих случаях, например, виртуальному агенту для того, чтобы понять, как вести себя с пользователем [9]. Но заставлять клиента проходить психологический тест во время его обслуживания было бы недопустимо. Возникает вопрос: а нельзя ли получить ту же информацию на основе обычной беседы на отвлеченную тему или же на основе самого процесса обслуживания клиента? Ведь человек – клерк или консьержка – делает именно это, причем чаще всего интуитивно и непреднамеренно. Может ли данную функцию выполнять автомат, анализируя наблюдаемое поведение человека?

Для ответа на этот вопрос было предпринято исследование, в котором испытуемые, прошедшие тест 5PFQ, отвечали на вопросы Регистратора (виртуальной консьержки) в процессе воображаемой регистрации в отель. Данные о поведении испытуемых сопоставлялись с результатами теста посредством статистического анализа. В итоге было найдено, что данные о поведении испытуемых при взаимодействии с Регистратором позволяют с некоторой точностью предсказать результаты теста 5PFQ.

Этот результат вселяет надежду на то, что будущие роботы и виртуальные агенты смогут понимать характер собеседника на интуитивном уровне, так же как люди, причем без использования биометрических приборов или психологических тестов. Кроме того, та же технология может быть использована и для оценки поведения самих виртуальных агентов и роботов, которых по понятным причинам нельзя подвергнуть психологическим тестам, разработанным для человека.

Материалы и методы

Примеры доступных онлайн тестов для психологического профилирования личности на русском языке включают «большую пятерку» (5PFQ) [10], тест Бойко [11], тест Кетелла [12], тест Мехрабиана [13], и другие. В данной работе использовался первый из них. Основные характеристики, получаемые в результате данного теста, сведены в табл. 1.

Таблица 1

Основные характеристики личности, определяемые тестом 5PFQ

Номер характеристики	Левая крайность	Правая крайность
1	интроверсия	экстраверсия
2	обособленность	привязанность
3	импульсивность	самоконтроль
4	эмоциональная устойчивость	эмоциональная неустойчивость
5	практичность	экспрессивность

Стимульный материал теста проиллюстрирован примерами в табл. 2. Весь опросник состоит из 75 пар противоположных по своему значению стимульных высказываний, характеризующих поведение человека. Испытуемые оценивают их по пятибалльной шкале (–2, –1, 0, 1, 2).

Таблица 2

Стимульный материал теста 5PFQ: первые 10 вопросов

№	Левая альтернатива	Правая альтернатива
1	Мне нравится заниматься физкультурой	Я не люблю физические нагрузки
2	Люди считают меня отзывчивым и доброжелательным человеком	Некоторые люди считают меня холодным и черствым
3	Я во всем ценю чистоту и порядок	Иногда я позволяю себе быть неряшливым
4	Меня часто беспокоит мысль, что что-нибудь может случиться	«Мелочи жизни» меня не тревожат
5	Все новое вызывает у меня интерес	Часто новое вызывает у меня раздражение
6	Если я ничем не занят, то это меня беспокоит	Я человек спокойный и не люблю суетиться
7	Я стараюсь проявлять дружелюбие ко всем людям	Я не всегда и не со всеми дружелюбный человек
8	Моя комната всегда аккуратно прибрана	Я не очень стараюсь следить за чистотой и порядком
9	Иногда я расстраиваюсь из-за пустяков	Я не обращаю внимания на мелкие проблемы
10	Мне нравятся неожиданности	Я люблю предсказуемость событий

Виртуальный рецепшионист отеля (Регистратор) был реализован в рамках данного исследования в нескольких вариантах: в консольном варианте без визуализации, в десктопном варианте на основе Matlab с упрощенной визуализацией, в десктопном и VR-вариантах на основе Unreal Engine 4 с реалистичной 3D графикой (рис. 1), а также в форме опросника на базе SurveyMonkey. Последняя версия и использовалась для статистического анализа, представленного здесь.

Экспериментальная процедура включает в себя диалог с Регистратором, в ходе которого уточняются возможность и детали поселения в отель.




Рис. 1. Воплощения Регистратора на базе Unreal Engine 4. А: виртуальное окружение в десктопном варианте. Внизу видно меню для ответа на вопрос. В, С: VR-вариант. В: вид окружения в шлеме. С: испытуемая в VR шлеме разговаривает с виртуальным актором

Диалог с Регистратором состоит из последовательности вопросов и ответов, причем каждый вопрос и каждый ответ имеют несколько predetermined вариантов, отличающихся по тональности высказываний. Начало их списка приведено в табл. 3. Здесь символ «№» обозначает номер вопроса, причем отрицательные номера соответствуют вопросам Регистратора, положительные – ответам посетителя.

Таблица 3

Стимульный материал Регистратора: первые 4 вопроса

№	Высказывание
–1	Вы подошли к стойке, но рецепшионистка не смотрит на вас: занята.
1	[Молчаливо ждать]
1	[Нажать звонок]
1	Гм-Гм.
1	Извините, я тороплюсь.
1	Прошу прощения.
–2	Здравствуйте, рада видеть вас в нашем отеле.
–2	Добрый вечер, добро пожаловать в наш отель.
–2	Здравствуйте. Слушаю вас.
2	Добрый вечер.
2	Здравствуйте.
2	Привет.
2	[молчание]
–3	Чем могу вам помочь?
–3	Вы хотели бы у нас остановиться?
–3	Буду рада вам помочь. Вас интересует наш отель?
3	Да, я хочу у вас остановиться.
3	Мне нужен номер.
3	Я думаю, у вас для меня должен быть номер.
3	Надеюсь, у вас есть места.
–4	У вас есть бронь?
–4	Номер брони, пожалуйста.
–4	Бронировался ли номер заранее? Если да, не напомним ли номер брони?
4	Бронь на меня должна быть, но номер я не знаю. Бронировал(а) не я.
4	Мне сказали, что номер будет забронирован, но номер не сообщили.
4	Да, но, к сожалению, номер брони я не знаю, и сейчас узнать не смогу.

Оценки тональностей каждого варианта каждого вопроса и ответа по трем шкалам были получены путем опроса группы 27 испытуемых. Полученные средние значения для первых четырех вопросов представлены в табл. 4. Здесь так же, как и в табл. 3, «№» обозначает номер вопроса, отрицательные номера соответствуют вопросам регистратора, положительные – ответам посетителя.

Всего в данном исследовании приняло участие 60 испытуемых – студентов НИЯУ МИФИ в возрасте от 21 до 28 лет, мужчины и женщины примерно в равной пропорции. Данные 36-ти из них оказались пригодными для основного анализа и были использованы в расчетах, как описано ниже.

Таблица 4

Оценки тональности вариантов вопросов и ответов: первые 4 вопроса

№	Валентность	Возбужденность	Доминантность	Вариант
-1	-0.22	-0.27	0.07	1
1	0.22	-0.31	-0.25	1
1	0.04	0.10	0.30	2
1	-0.15	0.21	0.08	3
1	0.03	0.43	0.24	4
1	0.36	-0.03	-0.12	5
-2	0.50	-0.39	0.09	1
-2	0.52	-0.37	0.08	2
-2	0.13	-0.09	0.04	3
2	0.30	-0.29	0.11	1
2	0.15	-0.12	0.08	2
2	-0.15	-0.22	0.29	3
2	-0.52	-0.02	-0.03	4
-3	0.47	-0.31	0.05	1
-3	0.35	-0.24	0.17	2
-3	0.56	-0.24	0.17	3
3	0.23	-0.32	0.02	1
3	-0.27	-0.04	0.27	2
3	0.12	-0.03	0.12	3
3	-0.01	0.29	-0.19	4
-4	-0.01	-0.14	0.15	1
-4	0.11	-0.22	0.34	2
-4	0.47	-0.18	0.05	3
4	0.18	0.15	-0.22	1
4	0.17	0.06	-0.25	2
4	0.30	0.02	-0.08	3

Статистический анализ проводился в среде Matlab с использованием функций `canoncorr` и `jackknife`. Процедура состояла в следующем.

1. В качестве исходных данных были взяты два набора векторов: данные Регистратора, X , и данные теста SPFQ, Y . При этом для каждого испытуемого i вектор x_i был составлен из оценок последовательности вариантов ответов, выбранных испытуемым.
2. Согласно процедуре JackKnife (функция `jackknife`) для каждого из 36 испытуемых по очереди производилось следующее:
 - а. строка в матрицах X , Y , соответствующая данному испытуемому i , выбрасывалась ($X \rightarrow X'$, $Y \rightarrow Y'$);

- б. вычислялись матрицы A, B на основе функции `canoncorr`:

$$[A, B] = \text{canoncorr}(X', Y'); \quad (1)$$

- в. вычислялось предсказание z_i для выброшенного вектора y_i на основе выброшенного вектора x_i по формуле

$$z_i = \langle Y' \rangle + (x_i - \langle X' \rangle) \cdot A/B, \quad (2)$$

где средние брались по матрицам с выброшенными векторами.

3. Полученный набор векторов $Z = \{z_i\}$ сравнивался с исходным Y по каждому из пяти выходных параметров теста 5PFQ: вычислялись коэффициенты корреляции Пирсона r и их значимость (p -value).

Результаты

Значимые корреляции были получены для последних двух из пяти характеристик, определяемых тестом 5PFQ (табл. 1): «практичность — экспрессивность» (рис. 2 А, $r = 0.96$, $p < 4\text{e-}19$) и «эмоциональная устойчивость — эмоциональная неустойчивость» (рис. 2Б, $r = 0.81$, $p < 6\text{e-}8$). При этом предсказания, выходящие за область изменения данных, были отброшены (не показаны на рис. 2). В первом случае (рис. 2А) была отброшена одна точка, во втором (рис. 2Б) — шесть точек из 36.




Рис. 2. Предсказания для пятого (А) и четвертого (Б) параметров теста 5PFQ

Полученные результаты указывают на принципиальную возможность количественного предсказания пятифакторных характеристик личности на основе рутинного диалога с воображаемым виртуальным агентом, без прохождения теста «большой пятерки». Хотя для большинства характеристик в данном исследовании не был получен положительный результат,

две из пяти предсказанных характеристик имеют высокие корреляции с результатами теста (до 0.96) и фактически позволяют делать предсказания с точностью порядка 20%.

Есть надежда на то, что результат может быть улучшен с использованием нейросетевого анализа. Работы в этом направлении ведутся. Кроме того, ожидается, что результаты должны улучшиться при использовании данных многомодального интерфейса: регистрируемой мимики, направления взгляда, интонации голоса, жестов испытуемого. Данные средства доступны в воплощениях Регистратора на основе виртуального окружения и виртуальной реальности (рис. 1).

Обсуждение

Воплощенные антропоморфные социальные агенты – как роботы, так и виртуальные акторы – становятся неотъемлемой частью жизни человека в самых различных ее сферах, включая сферы услуг, развлечений, образования, здравоохранения, и многие другие. При этом они выступают как ассистенты, помощники, персональные спутники, собеседники, регистраторы, виртуальные персонажи игр или представлений, партнеры, агенты-посредники, модераторы, тьюторы, эксперты, консультанты и т. д. Однако их до сих пор нельзя назвать *социально приемлемыми*, прежде всего вследствие отсутствия у них эмоционального интеллекта на уровне человека. Одна из причин существующего дефицита – это отсутствие достаточно общих и вместе с тем точных моделей, описывающих социально-эмоциональное поведение человека. Другая причина – это отсутствие метрик и измерительных средств, позволяющих в автоматическом режиме (без участия человека) оценивать качество таких моделей по наблюдаемому поведению виртуального актора или робота. Автоматический режим необходим для обучения моделей на больших объемах выборок, что невозможно осуществить на основе опросов испытуемых.

Представленный в настоящей работе результат позволяет надеяться, что, во-первых, будущие роботы и виртуальные агенты смогут обладать эмоциональным интеллектом, достаточным для понимания человеческой психики, и во-вторых, что качество искусственного эмоционального интеллекта может быть измерено автоматически.

В данной работе показано, что автоматическая количественная оценка перцептивных психологических характеристик виртуальных акторов по шкалам широко используемых сегодня психологических тестов возможна на основе наблюдения их естественного поведения при выполнении их

прямых функций. В самом деле, в роли клиента, регистрирующегося в отель, мог бы выступать автомат.

Кроме того, представленный результат показывает, что виртуальный агент может «понимать» характер собеседника на основе его поведения без использования специальных измерительных приборов или тестов. А это значит, что агенты, обладающие эмоциональным интеллектом, смогут информировано выбирать адекватное поведение и таким образом достигать социальной совместимости на уровне человека.

Можно ожидать, что такие социальные агенты станут полезными для регуляции эмоций пользователей с приложениями в области сервисно-ориентированного искусственного интеллекта. Модели эмоций можно будет использовать для создания адекватной реакции агента для достижения желаемого эффекта регулирования эмоций. Здесь будет полезна основанная на когнитивной архитектуре eBICA [14, 15] модель эмоционального взаимодействия, сочетающая концепции, заимствованные из биологии, когнитивной психологии, социологии и этики. Ожидаемый эффект на жизнь общества в целом включает новые технологии интеллектуального регулирования эмоций и новые средства для эмоционального общения с артефактами и их посредством.

В ходе дальнейших исследований предполагается разработка нейросетевой модели управления виртуальным актором. За структурную основу предполагается взять модель работы диалогового ассистента, разработанную лабораторией DeepPavlov [16]. Она представляет собой микросерверную архитектуру, включающую в себя в том числе такие компоненты, как аннотатор (классификатор намерений пользователя), генератор ответа, и селектор ответов.

Выводы

В работе представлено экспериментальное подтверждение возможности получения количественных пятифакторных характеристик личности без проведения явного психологического тестирования, на основе анализа данных поведения человека при выполнении им рутинной процедуры регистрации в отель. Данную методику можно назвать «Психометр», так как она является новой разновидностью измерительного средства, выполняющего количественную психометрию скрытым образом.

Программа дальнейших исследований включает расширение парадигмы до произвольного диалога с артефактом в открытом сценарии взаимодействия, использование воплощенного виртуального агента или робота, использование многомодального человеко-машинного интерфейса и глу-

бокого обучения нейросетевых моделей для реализации функций эмоционального интеллекта.

Работа финансирована грантом РФФИ № 22-11-00213. Автор благодарен Алексею Михневу, Владимиру Царькову, Анатолию Долгих и другим студентам НИЯУ МИФИ, принявшим участие в работе над проектом.

Список литературы

1. Cattell R.B., Cattell A.K., Cattell H.E.P. 16PF Fifth Edition Questionnaire. Champaign, IL: IPAT. 1993.
2. Бойко В.В. Энергия эмоций в общении: взгляд на себя и на других. Москва : Филинь. 1996.
3. Mehrabian A., Epstein N. A measure of emotional empathy // Journal of Personality. 1972. V. 40, N 4. P. 525–543.
4. McCrae R.R., Costa P.T. Validation of the five - factor model of personality across instruments and observers // Journal of Personality and Social Psychology. 1987. V. 52. P. 81–90.
5. Кравцова О.А., Прокофьева Т.Ю., Шайгерова Л.А., Солдатов Г.У. Психодиагностика толерантности личности. Смысл, 2008.
6. Matthews G., Deary I.J., Whiteman M.C. Personality traits. Cambridge University Press. 2003.
7. Хромов А.Б. Пятифакторный опросник личности : учебно-методическое пособие. Курган : КГУ. 2000.
8. Karson W., O'Dell J.W. A Guide to the Clinical Use of the 16PF. University of Michigan Press, Ann Arbor. 1976.
9. Marsella S., Gratch J., Petta P. Computational models of emotion // Scherer K.R., Bänziger T., Roesch E. (Eds.) A Blueprint for Affective Computing: A sourcebook and manual. Oxford : Oxford University Press, 2010.
10. <https://psytests.org/bigfive/5pfq.html>
11. <https://psytests.org/boyko/empathy.html>
12. <https://psytests.org/cattell/16pfA.html>
13. <https://psytests.org/emotional/eets.html>
14. Samsonovich A.V. Emotional biologically inspired cognitive architecture // Biologically Inspired Cognitive Architectures. 2013. N 6. P. 109–125.
15. Samsonovich A.V. Socially emotional brain-inspired cognitive architecture framework for artificial intelligence // Cognitive Systems Research. 2020. V. 60. P. 57–76.
16. <https://deeppavlov.ai/>

**Л.Е. СЕЛЕЗНЕВ, А.А. ЧУПАХИН, В.А. КОСТЕНКО,
А.В. ВАРТАНОВ, А.О. ШЕВЧЕНКО**

Московский государственный университет им. М.В. Ломоносова
andrewchup@lvk.cs.msu

РАСПОЗНАВАНИЕ МЫСЛЕННО ПРОИЗНОСИМЫХ ФОНЕМ С ИСПОЛЬЗОВАНИЕМ СВЁРТОЧНЫХ НЕЙРОННЫХ СЕТЕЙ НА ОСНОВАНИИ ДАННЫХ ЭЛЕКТРОЭНЦЕФАЛОГРАФИИ*

Рассматривается задача бинарной и многоклассовой классификации мысленно произносимых фонем русского языка на основе данных, полученных с многоканального устройства электроэнцефалографии. Описывается методика проведения эксперимента по сбору данных, а также методы обработки полученных данных. Предложен, реализован и исследуется алгоритм классификации на основе свёрточных нейронных сетей.

Ключевые слова: *свёрточные нейронные сети, электроэнцефалография, классификация.*

Введение

Задача разработки интерфейсов общения человека и компьютера была актуальна с момента создания первых ЭВМ. Кроме классических устройств ввода-вывода (компьютерная клавиатура, мышь, монитор) также предпринимались попытки по созданию устройств, основанных на нейроинтерфейсах, способных считывать команды напрямую из мозга для управления курсором мыши [1], для распознавания области экрана, на которую смотрит пользователь [2], для детектирования микроснов, в частности у водителей [3], а также для воссоздания наблюдаемых образов [4]. Решение задач, связанных с человеко-компьютерным интерфейсом, позволит помочь людям с различными нарушениями, к примеру, помогая парализованным самостоятельно управлять компьютером [5] или транспортом [6]. В данной работе рассматривается задача распознавания мысленно произносимых фонем русского языка на основании данных, получаемых с устройства электроэнцефалографии (ЭЭГ). Фонема представляет собой минимальную смысловоразличительную единицу языка, не имею-

* Данная работа выполнена при частичной поддержке Некоммерческого Фонда развития науки и образования «Интеллект».

щую самостоятельного лексического или грамматического значения, но служащую для различения и отождествления значимых единиц языка таких, как морфемы и слова. Задача актуальна по причине малой разработанности области распознавания фонем русского языка при существующих аналогичных разработках для фонем английского языка [7].

В данной работе рассмотрен метод на основе свёрточных нейронных сетей для распознавания и классификации мысленно произносимых фонем. Данная работа является развитием исследования [8].

Способ извлечения и сбора данных

Для решения задачи извлечения и сбора данных используется неинвазивный метод на основе ЭЭГ, подробно описанный в работе [8], использующий накладные электроды и наиболее простой в реализации, не требующий хирургического вмешательства. В качестве фонем выбраны 7 фонем из различных групп классификации Плоткина [9]: /a/, /b/, /f/, /g/, /m/, /r/, /u/.

Для сбора данных использовался подход, состоящий из трех этапов: на первом этапе испытуемому демонстрируется стимул, на втором этапе начинается внутреннее проговаривание фонемы и ведётся запись данных, на третьем этапе испытуемому даётся небольшой перерыв. В качестве стимулов используется аудиальный стимул (запись произношения фонемы) или визуальный стимул (изображение фонемы), и порядок фонем является случайным для испытуемого.

Предварительная обработка и разбиение данных

В работе [8] подробно описан алгоритм предобработки данных. Для понимания дальнейшего изложения приведем описание только результатов предобработки данных. Полученные после предобработки данные содержат 800-миллисекундные интервалы мысленного проговаривания фонем, включая 200-миллисекундный интервал, предшествующий началу мысленного проговаривания (итого 600 миллисекунд мысленного проговаривания фонемы).

Математическая постановка задачи распознавания

В работе рассматривается задача построения классификатора нейрофизиологических сигналов мысленного проговаривания заданного набора фонем русского языка, относящихся к различным классам фонем: /a/, /b/, /f/, /g/, /m/, /r/, /u/. Помимо классов фонем существует также разделение данных между разными испытуемыми, что необходимо учитывать ввиду

специфики тестовой среды (несмотря на одинаковый подход к сбору данных, данные могут значительно отличаться для разных людей ввиду присутствия различий в устройстве головного мозга).

Обозначим за $W_{\varphi,i} = \{w_{\varphi,i,k}\}$ множество временных рядов сигнала, соответствующего примеру под номером k для записи одной из 7 рассматриваемых фонем φ ($1 \leq \varphi \leq 7$), полученной для одного из 12 испытуемых под номером i ($1 \leq i \leq 12$). Длительность временного ряда $\{w_{\varphi,i,k}\}$ соответствует 800 миллисекундам, 200 миллисекунд предшествуют мысленному проговариванию фонем и не используются для классификации. Множество W_i (множество всех данных для испытуемого под номером i) разбивается на два подмножества в заранее заданной пропорции с целью выделения обучающих и тестовых выборок данных.

Для обозначенных данных требуется разработать алгоритм построения классификатора, позволяющего с заданной точностью классифицировать получаемый сигнал. В результате работы построенного классификатора ожидается номер фонемы, к которому алгоритм отнёс поданный ему временной ряд.

В качестве описанной метрики числа верно классифицированных временных рядов используется метрика доли верных совпадений:

$$MATCH_i = \frac{\sum_{w \in W_{\varphi,i}, 1 \leq \varphi \leq 7} 1_{\text{classifier}_i(w)=\varphi}}{|\{w: w \in W_{\varphi,i}, 1 \leq \varphi \leq 7\}|},$$

где classifier_i – классификатор, построенный с использованием обучающей выборки для испытуемого с номером i , результатом работы которого является номер фонемы, $|\{w: w \in W_{\varphi,i}, 1 \leq \varphi \leq 7\}|$ – общее число временных рядов, полученных для испытуемого i и фонемы φ . Помимо всего множества $W_{\varphi,i}$, может также использоваться его подмножество – тестовая выборка.

В качестве описанной метрики числа неверно классифицированных временных рядов в случае применения классификатора для испытуемого i к данным, относящимся к другому испытуемому j , используется метрика:

$$FAIL_{i,j} = \frac{\sum_{w \in W_{\varphi,j}, 1 \leq \varphi \leq 7} 1_{\text{classifier}_i(w)=\varphi}}{|\{w: w \in W_{\varphi,j}, 1 \leq \varphi \leq 7\}|},$$

где classifier_i – классификатор, построенный с использованием обучающей выборки для испытуемого с номером i , результатом работы которого является номер фонемы, $|\{w: w \in W_{\varphi,j}, 1 \leq \varphi \leq 7\}|$ – общее число временных рядов, полученных для испытуемого j и фонемы φ . Помимо всего множества $W_{\varphi,j}$, может также использоваться его подмножество – тестовая выборка.

Задача алгоритма построения классификатора сводится к построению классификатора, максимизирующего долю правильно классифицированных рядов в случае применения алгоритма к данным для одного и того же испытуемого (метрики $MATCH_i$), а также минимизации доли неправильно классифицированных рядов в случае применения алгоритма, построенного для испытуемого под номером i к данным, полученным для испытуемого j (метрики $FAIL_{i,j}$):

$$|MATCH| \rightarrow \max,$$

$$|FAIL| \rightarrow \min.$$

В описанных выше задачах минимизации и максимизации рассматривается минимизация и максимизация среднеквадратичных норм векторов $MATCH$ и $FAIL$, в качестве нормы рассматривается MSE.

Для сравнения алгоритма с существующими подходами к решению данной задачи дополнительно рассматривается оценка попарной классификации фонем. Пусть φ_1, φ_2 – номера двух любых различных фонем. Классификатор обучается, рассматривая всего два класса фонем – φ_1, φ_2 , для заданного испытуемого i . Тогда точность классификации будет оцениваться по метрике $MATCH_i$ для задачи бинарной классификации для всех возможных неповторяющихся пар фонем φ_1, φ_2 при условии, что $1 \leq \varphi_{1,2} \leq 7$. По полученным данным оценивается средняя точность бинарной классификации, максимальная и минимальная точность бинарной классификации.

Описание алгоритма

В качестве архитектуры предлагается свёрточная нейронная сеть, состоящая из L свёрточных и подвыборочных слоёв и R полносвязных слоёв без учета выходного слоя (рис. 1).




Рис. 1. Архитектура свёрточной нейронной сети

$C_{l_i}, C_{l_w}, C_{l_h}$ задают число каналов i свёрточного слоя, а также ширину и высоту свёрточного ядра для i свёрточного слоя. P_{l_w}, P_{l_h} задают ширину и высоту подвыборочного ядра для i подвыборочного слоя. Общее число пар свёрточных и подвыборочных слоёв составляет L .

D_r задаёт число нейронов полносвязной сети, M задаёт число выходных нейронов всей сети. Число полносвязных слоёв без учета последнего слоя – R .

Для решения проблемы переобучения и проблем затухающих и растущих градиентов, применяются дополнительные *Dropout* слои. Доля «исключаемых» параметров для каждого свёрточного слоя i задаётся значением Q_i . Доля «исключаемых» параметров для каждого полносвязного слоя r задаётся значением S_r .

В рамках работы рассматриваются несколько задач и соответствующих им архитектур сетей, полученных во время экспериментального исследования с помощью автоматизированного подбора параметров. Были рассмотрены следующие задачи:

1. Для каждого отдельного испытуемого рассматривается задача бинарной классификации для всех возможных неповторяющихся пар фонов.
2. Для каждого отдельного испытуемого рассматривается задача многоклассовой классификации с числом классов, равным числу фонов.
3. Для объединения данных всех испытуемых рассматривается задача бинарной классификации для всех возможных неповторяющихся пар фонов.

4. Для объединения данных всех испытуемых рассматривается задача многоклассовой классификации с числом классов, равным числу фонем.

Разделение задачи классификации на 4 подзадачи в зависимости от рассматриваемых данных и типа классификатора необходимо ввиду трудности создания архитектуры сети, способной эффективно решить каждую из задач одновременно.

Число выходных нейронов сети M зависит от рассматриваемой подзадачи классификации: в задачах 1 и 3, $M = 1$ (что соответствует вероятности выбора одной из двух фонем для бинарной классификации), в задачах 2 и 4, $M = 7$ (что соответствует числу фонем в задаче многоклассовой классификации).

В качестве функций активации каждого слоя во всех четырех подзадачах используется *ReLU*, в дополнение к ней в 1 и 3 задачах используется сигмоидальная функция активации. Применяется метод пакетного градиентного обратного распространения ошибки с использованием функции потерь *CrossEntropyLoss* для многоклассовой классификации и *BinaryCrossEntropyLoss* в случае бинарной классификации.

Итоговый алгоритм состоит из следующих компонентов:

1. Алгоритм основан на свёрточных нейронных сетях с использованием как свёрточных, так и подвыборочных слоёв, общие параметры сети задаются в зависимости от типа рассматриваемой задачи.
2. Алгоритм обучается пакетным алгоритмом градиентного обратного распространения ошибки заданное число эпох с использованием постепенного снижения коэффициента обучения.
3. Для увеличения числа обучающих примеров предлагается аугментировать исходные данные.

Результаты экспериментального исследования

В задаче 1 средняя точность по всем запускам среди всех испытуемых и пар фонем составляет 73.98% (среднее значение всех ячеек табл. 1), что превосходит аналогичную метрику на тех же данных в работе [8], составившую 67%. Средняя по всем запускам и всем испытуемым точность попарной классификации для всех пар фонем представлена в табл. 1, средняя точность по всем запускам попарной классификации для лучшего испытуемого приведена в табл. 2. Средняя точность попарной классификации для всех испытуемых и всех фонем по всем запускам, составляю-

шая 73.98% (среднее значение всех ячеек табл. 1), или максимальная средняя по всем испытуемым и всем запускам точность попарной классификации, составляющая 80.60% (максимальное значение среди ячеек табл. 1) для фонем Б и Ф, что сравнимо с максимальной точностью попарной классификации для наилучшего испытуемого в работе [8], составляющей 81%.

Таблица 1

Средняя попарная классификация по всем запускам и испытуемым

	А	Б	Ф	Г	М	Р	У
А		76.75%	75.06%	73.17%	78.12%	78.14%	75.33%
Б			80.60%	77.71%	72.96%	73.66%	70.70%
Ф				75.22%	76.57%	67.23%	74.82%
Г					66.09%	75.60%	71.46%
М						76.36%	67.55%
Р							70.52%
У							

Таблица 2

Лучшая попарная классификация в среднем по всем запускам, испытуемый 1

	А	Б	Ф	Г	М	Р	У
А		94.87%	54.65%	82.89%	83.70%	82.89%	86.59%
Б			91.25%	92.86%	89.53%	94.29%	85.90%
Ф				82.05%	77.66%	76.92%	74.42%
Г					80.95%	97.14%	89.47%
М						88.10%	77.78%
Р							84.21%
У							

В задаче 2 средняя точность на всех запусках составляет 61.98%, что связано с неудачными начальными инициализациями сетей в некоторых случаях, приводившими к необучаемости сети, а также с малыми размерами обучающих выборок для отдельных испытуемых. В этих случаях (два испытуемых) средняя точность классификации не поднялась выше 20%. Максимальная средняя точность по всем запускам среди всех испытуемых составляет 80.34% (усреднение точности для каждого испытуемого по всем запускам), общая максимальная точность среди всех запусков и всех испытуемых составляет 97.71%. Таким образом, алгоритм обучения можно комбинировать с алгоритмом мультистарта с последующим выбо-

ром лучшей сети среди обученных для каждого испытуемого в отдельности.

Для задачи 3 результаты приведены в табл. 3, общая средняя точность по всем запускам составляет 76.44%, тогда как максимальная средняя по всем запускам точность составляет 93.02%. Несмотря на полученную среднюю и максимальную точности, для некоторых пар фонем точность бинарной классификации близка к случайному угадыванию, что согласуется с результатами работы [8] и схожих работ.

Таблица 3

Точность попарной классификации для всех данных

	А	Б	Ф	Г	М	Р	У
А		63.46%	93.02%	76.84%	92.87%	90.75%	86.20%
Б			53.52%	79.86%	71.69%	74.83%	78.34%
Ф				80.87%	82.75%	88.77%	63.02%
Г					59.01%	58.88%	66.41%
М						87.00%	79.42%
Р							77.74%
У							

В задаче 4 многоклассовой классификации на данных всех испытуемых точность классификации на лучшем из 3 запусков составляет 80.18%. Обученную на данных всех испытуемых сеть впоследствии можно применять в качестве предобученной сети для более точного дообучения под отдельных испытуемых. Обученная на данных всех испытуемых сеть позволяет изначально значительно снизить величину метрики *FAIL* и повысить величину метрики *MATCH*, таким образом позволяя решить поставленную ранее задачу оптимизации.

Выводы

Предложен и реализован алгоритм для распознавания и классификации мысленно произносимых фонем на основе свёрточных нейронных сетей. Предложенные в работе архитектуры нейронных сетей и гиперпараметры алгоритма обучения позволяют с достаточной точностью в сравнении с существующей работой [8] на тех же данных решить поставленную задачу не только бинарной, но и многоклассовой классификации, не рассмотренной ранее в [8].

Программа дальнейших исследований будет включать в себя применения алгоритма мультистарта при обучении нейронных сетей для повышения точности классификации, а также исследование методов генерации синтетических данных с целью обогащения объема исходных данных.

Список литературы

1. Li Y. [et al.]. An EEG-based BCI system for 2D cursor control // 2008 IEEE International Joint Conference on Neural Networks (IEEE World Congress on Computational Intelligence). 2008. P. 2214–2219.
2. Buragohain S., Kashyap K. Mouse Cursor Control using EEG Signal and Machine Learning // International Journal of Computer Sciences and Engineering. 2019. N 5. P. 1623–1627.
3. Коваленко Д. С. Методы и программные средства обучения алгоритмов распознавания участков фазовых траекторий: специальность 05.13.11 «математическое и программное обеспечение вычислительных машин, комплексов и компьютерных сетей»: диссертация на соискание ученой степени кандидата технических наук. Московский государственный университет им. М.В. Ломоносова. Москва, 2010. 168 с.
4. Ogórek K., Poryzala P., Strumillo P. EEG Based Image Reconstruction Using Transformers // Biocybernetics and Biomedical Engineering – Current Trends and Challenges. Lecture Notes in Networks and Systems. 2022. N 293. P. 51–63.
5. Bensch M. [et al.]. Nessi: An EEG-Controlled Web Browser for Severely Paralyzed Patients // Computational Intelligence and Neuroscience. 2007. V. 2007.
6. Sahat N., Alias A., Yassin F.M. Wheelchair controlled by human brainwave using brain-computer interface system for paralyzed patient // Bulletin of Electrical Engineering and Informatics. 2021. N 6. P. 3032–3041.
7. Xuemin Chi, Hagedorn J., Schoonover D., D'Zmura M. EEG-based discrimination of imagined speech phonemes // International Journal of Bioelectromagnetism. 2011. V. 13, N 4. P. 201–206.
8. Gavrilenko Y., Saada D., Ilyushin E., Vartanov A.V., Shevchenko A. The Electroencephalogram Based Classification of Internally Pronounced Phonemes // Samsonovich, A.V., Gudwin, R.R., Simões, A.d.S. (eds) Brain-Inspired Cognitive Architectures for Artificial Intelligence: BICA*AI 2020. BICA 2020. Advances in Intelligent Systems and Computing. Springer, Cham. 2020. V. 1310. P. 97–105.
9. Плоткин В. Фонологические кванты. Москва : Наука. 1993.

В.Я. СЕРГИН

Институт математических проблем биологии РАН – филиал Института
прикладной математики им. М.В. Келдыша Российской академии наук
Московская область, Пушкино
v.sergin@mail.ru

ПРИРОДА И НЕЙРОННЫЕ МЕХАНИЗМЫ СОЗНАНИЯ

В статье рассматриваются нейронные механизмы сенсорного осознания, порождения мысли и дискурсивного мышления. Показано, что в основе осознания и порождения мысли лежат высокочастотные циклические процессы автоотождествления. В основе дискурсивного мышления лежат процессы сенсорно-моторного повторения. Эти взаимодействующие механизмы позволяют нам формировать образы, сцены и диалоги, наблюдать и изменять их, создавая подвижный и управляемый мир сознательно-го опыта.

Ключевые слова: *автоотождествление, осознание, сознание, мысль, дискурсивное мышление, интуиция.*

Введение

Современный обзор и анализ теоретических подходов к проблеме исследования сознания содержатся в работе [1]. Мы не будем останавливаться на их рассмотрении в нашей краткой статье. Заметим только, что можно назвать две частные проблемы, решение которых могло бы пролить свет на природу и механизмы сознания. Одной из них является выяснение нейронных механизмов, порождающих феномен осознания внешних и внутренних событий. Необходимо понять, как мы осознаем что бы то ни было, например вспышку света, запах или боль. Другая проблема связана со способностями людей к произвольному оперированию знаниями. Феноменологически эти процессы выражаются мыслями. Что такое мысль и какие нейрофизиологические механизмы лежат в основе наших способностей к мышлению?

Автоотождествление как ключевой механизм осознания

Природа и нейронные механизмы осознания сенсорных событий подробно рассмотрены в моих статьях [2, 3]. В этих работах показано, что в основе процесса осознания может лежать нейробиологический механизм представления собственных знаний в явной форме.

Действительно, способность осуществлять явное внутреннее представление как внешних объектов, так и конструируемых внутри образов, является наиболее ярким и специфическим свойством сознания. Функционирование сознания всегда связано с явными представлениями образов, символов, звуков, запахов и т. п., и неотделимо от них. Никакая сознательная деятельность мозга невозможна без явного представления данных, которое, вероятно, является ключевым процессом осознания.

Если это действительно так, то какой нейробиологический механизм может осуществлять явное представление данных и тем самым порождать психически переживаемый феномен их осознания? Как известно, процесс восприятия сенсорного события вызывает в нескольких областях коры головного мозга специфическое распределение нейронной активности. Можно предположить, что специфический паттерн возбуждения выходных нейронов передается на входные нейроны тех же областей коры через автономные обратные связи (рис. 1). Совпадающие (тождественные) паттерны возбуждения, порождаемые стимулом и передаваемые по обратным связям, складываются на одних и тех же нейронных структурах, вызывая их интенсивную разрядку.




Рис. 1. Локальная схема процесса автоотождествления. Связи с другими структурами мозга не показаны [2]

Такой циклический процесс с положительной обратной связью увеличивает интенсивность отображения стимула, что создает наилучшие условия его категоризации распределенной долговременной памятью. Результат категоризации (свет, звук, запах) отображается специфическим паттерном нейронной активности, который включается в цикл авто-

отождествления, обеспечивая интенсивное отображение субъективного смысла стимула.

Отображение сенсорных категорий паттернами входной нейронной активности коры есть представление внутренних данных самому себе в качестве элементов отображения внешнего мира. В результате внешний мир оказывается представленным субъекту не в объективных физических характеристиках, а в сенсорных категориях: свет, звуки, запахи, прикосновения и т. п., что является наиболее специфическим переживанием сенсорного осознания.

Следует подчеркнуть, что осознается не входное возбуждение, а сенсорные категории, которые порождаются нейронной структурой коры в ответ на входное возбуждение. Сенсорные категории – это внутренние данные, которые содержатся в памяти, а процесс автоотождествления является способом представления этих данных в явной форме. Это значит, что внешнее событие сначала должно быть воспринято и представлено в сенсорных категориях, и только потом мозг сможет осознать его. Осознание оказывается формой вторичной обработки данных.

Сенсорное осознание – это осознание внешних событий, которые отображаются паттернами нейронной активности коры и становятся внутренними сигналами мозга. В процессе мышления операционная активность мозга также отображается паттернами нейронной активности коры. Поэтому нейрофизиологический механизм осознания результатов операционной активности мозга может быть совершенно аналогичен механизму осознания сенсорных данных. Механизм автоотождествления оказывается универсальным аппаратом осознания сигналов как порождаемых сенсорным входом, так и генерируемых самим мозгом.

Процессы сознательного восприятия

Существует ли механизм автоотождествления в действительности? Если этот циклический механизм действительно существует, то его функционирование должно порождать вполне определенные и предсказуемые свойства процесса осознания. Тогда сопоставление теоретически предсказанных и экспериментально установленных свойств сознательного восприятия позволит подтвердить или опровергнуть существование механизма автоотождествления.

В работах [2, 3] показано, что гипотеза автоотождествления влечет за собой точно формулируемые следствия в отношении временных и частотных характеристик осознания сигналов. Дается теоретическая оценка времени цикла автоотождествления, которая составляет приблизительно 50 мс.

Анализ обширных психологических и психофизических данных, относящихся к таким феноменам, как перцептивный момент, временной порог, временная суммация, обратная маскировка, слияние мерцаний и др., позволяет оценить время цикла автоотождествления величиной порядка нескольких десятков миллисекунд, которая может варьировать в диапазоне от 10 мс до 100 мс. Следовательно, соответствующую полосу частот циклических процессов можно оценить диапазоном приблизительно от 10 Гц до 100 Гц.

Процессы автоотождествления реализуются в обширных областях коры головного мозга. Если эти циклические процессы действительно существуют, то они могут быть обнаружены прямыми измерениями электрической активности коры. F. Crick and C. Koch выполнили анализ обширных электрофизиологических данных и обнаружили, что зрительное осознание коррелирует с высокочастотной электрической активностью коры головного мозга в диапазоне 30–70 Гц [4, 5]. Многочисленные исследования такого рода показывают, что высокочастотные колебания электрической активности, которые должны порождаться процессами автоотождествления в коре головного мозга, не только существуют в действительности, но и являются доминирующими.

Из анатомических и нейрофизиологических данных известно, что структура коры головного мозга состоит из сотен миллионов вертикально ориентированных популяций нейронов (мини колонок) с множеством связей по вертикали и с относительно небольшим числом горизонтальных связей [6]. Эти модули обработки содержат массивированные корко-корковые обратные связи, передающие возбуждение непосредственно или через ядра подкорковых структур. Установлено также, что подавляющее большинство обратных связей являются положительными. Такая анатомическая организация коры обеспечивает наилучшие условия реализации циклических процессов автоотождествления.

Таким образом, независимые экспериментальные данные психологии, психофизики, электрофизиологии и анатомии коры головного мозга подтверждают реалистичность процессов автоотождествления. Выполненные исследования позволяют утверждать, что осознание – это процесс представления внутренних данных в явной форме. Явное символическое представление сенсорных данных порождает сенсорное осознание. Явное символическое представление результатов операционной активности мозга порождает мысль. Если зрительное осознание – это видение внешних событий, то мысль – это видение результатов операционной активности мозга [2, 3].




Рис. 2. Функциональная схема системы сознательного восприятия. Восходящее сенсорное возбуждение и обратные связи показаны одианными линиями. Двойными линиями показаны автономные обратные связи механизма автоотождествления [7]

Систему сознательного восприятия, по одному из сенсорных путей, можно представить схемой, показанной на рис. 2. Хотя процессы неосознаваемого восприятия и осознания тесно связаны между собой и протекают в одних и тех же областях коры, их нейронные механизмы различны и четко разделяются анатомически и функционально. В системе неосознаваемого восприятия сенсорное возбуждение передается вверх, от проекционных к ассоциативным областям. На каждом вышележащем уровне обработки формируются характеристики, объемлющие данные нижележащих уровней. Обратные связи системы восприятия передают нисходящее возбуждение. Нисходящее возбуждение избирательно стимулирует нейронные ансамбли нижележащих уровней, облегчая передачу тех компонентов сенсорного возбуждения, которые соответствуют высшей объемлющей характеристике данного акта восприятия [8, 9]. Например, если объемлющей характеристикой является решетка, то могут стимулироваться нейронные популяции нижележащих уровней, реагирующие на линии определенных ориентаций.

Основой перцептивного сознания являются массивованно-параллельные автономные обратные связи, которые осуществляют передачу паттерна категоризации, порождаемого данной областью коры, на ее собственный вход. Эти циклические процессы с положительной обратной связью формируют интенсивное отображение сенсорных признаков и их объемлющих характеристик.

Сенсорно-моторное повторение и операционное сознание

Люди способны осознавать результаты операционной активности мозга и могут управлять этой активностью, то есть думать. Как нам удастся

управлять операционной активностью мозга и какие механизмы лежат в основе наших способностей к мышлению?

Ключевая идея, позволяющая ответить на этот вопрос, состоит в том, что явное символическое представление внутренних данных позволяет произвольно управлять ими как обособленными объектами. Примером произвольного управления может служить вербальное повторение: человек произносит слово, слышит его, запоминает, произносит вновь и т. д. Это циклический вербальный процесс сенсорно-моторного повторения. Слова не обязательно произносить вслух, человек может повторять их про себя, что составляет процесс внутреннего сенсорно-моторного повторения. Повторение – управляемый процесс, его можно прерывать и возобновлять вновь, его содержание можно произвольно изменять.

Процедура повторения может обеспечивать последовательность и непрерывность процесса рассуждений, его связанность и однозначность. В этих свойствах рассудочного мышления легко просматриваются характерные черты моторной системы, функционирование которой осуществляется посредством выбора единственной из множества потенциальных команд, их последовательного выполнения и строгой связанности последовательных действий. Программный аппарат моторной системы, формирующий связанную однозначную последовательность двигательных актов, точно так же формирует связанную однозначную последовательность слов или символов. Схематичное, жестко определенное и логичное рассудочное мышление формируются программным аппаратом моторной системы.

Систему оперирования данными, которая осуществляет такие функции как рассудочное и образное мышление, будем называть *операционным сознанием* [10, 11]. Механизм сенсорно-моторного повторения является базовым средством операционного сознания. Экспериментальные данные показывают, что частота вербального повторения составляет 3–6 Гц, частота зрительного повторения несколько ниже [12]. Частота повторения является тактовой частотой операционного сознания как системы обработки данных.

Программный аппарат моторной системы является источником рациональности мышления. Рациональность порождается тем, что действия моторной системы причинно-обусловлены. Эта причинная обусловленность воспроизводима посредством аппарата сенсорно-моторного повторения и наблюдаема посредством аппарата автоотождествления. Воспроизводимость и наблюдаемость делают возможным выявление причинно-

следственных связей. Способность устанавливать причинно-следственные связи является ключевым свойством человеческого разума.




Рис. 3. Схема взаимодействия процессов сенсорно-моторного повторения и осознания данных [10]

Процедура сенсорно-моторного повторения доступна обозрению и управляема. Физиологически это возможно потому, что повторение является низкочастотным процессом (3–6 Гц) и его содержание доступно обозрению с помощью высокочастотного аппарата автоотождествления (30–70 Гц). Взаимодействующие механизмы сенсорно-моторного повторения и автоотождествления позволяют нам формировать образы, сцены и диалоги, наблюдать и изменять их, создавая подвижный и управляемый мир сознательного опыта.

В отсутствие волевых усилий имеет место мышечная релаксация. Программный аппарат моторной системы, определяющий последовательность и жесткую связность процесса мышления, перестает быть доминирующим. В этом случае мысль не контролируется программным аппаратом моторной системы, и она формируется в соответствии со свободными ассоциациями.

Спонтанная перестройка сознания определяет подвижность, чуткость к эмоциональному состоянию и непредсказуемость свободного мышления. Влияние глубинной неосознаваемой мотивации на операционную активность мозга возрастает. Мысль движется по скрытым путям субъективной обусловленности. Озарение или интуиция не связаны с рассуждениями. Они имеют характер непосредственного видения результатов операционной активности мозга.

Глобальная модель сознания

Глобальную модель сознания можно представить схемой, показанной на рис. 4.




Рис. 4. Блок-схема глобальной модели сознания [10]

Неосознаваемая обработка осуществляется массивованно-параллельной системой, которая включает миллионы параллельно работающих модулей (мини-колонок) коры головного мозга.

Сознание реализуется в тех же областях коры головного мозга, где осуществляется неосознаваемая обработка данных. Область реализации

сознания, – это множество нейронных структур коры больших полушарий, охваченных циклическими процессами автоотождествления. Эти циклические процессы создают относительную обособленность сознания от остальной психики и формируют его подвижную организацию. Поочередная активация циклических процессов в тех или иных областях коры обеспечивает, в соответствии со специализацией этих областей, включение в процесс сознательного восприятия сигналов тех или иных сенсорных модальностей, сигналов внешнего окружения или внутреннего мира субъекта.

Заключение

Явные события – это события вне воспринимающей системы, то есть внешние события, что отличает их от неявных событий, происходящих внутри воспринимающей системы. Механизм автоотождествления позволяет представлять внутренние данные на входы нервной системы, что делает возможным их восприятие в явной форме.

Осознание – это процесс представления внутренних данных в явной форме. Явное символическое представление сенсорных данных порождает сенсорное осознание. Явное символическое представление результатов операционной активности мозга порождает мысль. Если зрительное осознание – это видение внешних событий, то мысль – это видение результатов операционной активности мозга.

Сознание – это система оперирования данными, представленными в явной форме. Явное символическое представление внутренних данных позволяет управлять ими как обособленными объектами. Произвольное управление данными возможно посредством механизма сенсорно-моторного повторения. Программный аппарат моторной системы, формирующий связанную однозначную последовательность двигательных актов, так же формирует связанную однозначную последовательность образов, слов или символов.

Череда мысленных образов, слов или символов управляема посредством программного аппарата моторной системы и доступна обозрению посредством механизмов автоотождествления. Взаимодействующие процессы сенсорно-моторного повторения и автоотождествления позволяют нам формировать образы, сцены и диалоги, наблюдать и изменять их, создавая подвижный и управляемый мир сознательного опыта.

Построенная модель сознания доступна проверке: из нее следует ряд принципиальных утверждений о функционировании мозга, которые могут быть опровергнуты или подтверждены экспериментально.

Список литературы

1. Анохин К.В. Когнитом: в поисках фундаментальной нейронаучной теории сознания // Журнал высшей нервной деятельности. 2021. Т. 71, № 1. С. 39–71.
2. Сергин В.Я. Авто-отождествление паттернов нейронной активности как физиологический механизм осознания // Журнал высшей нервной деятельности. 2016. Т. 66, № 3. С. 259–278.
3. Sergin V.Ya. Auto-Identification of Neuronal Activity Patterns as a Physiological Mechanism of Awareness // Neuroscience and Behavioral Physiology. 2017. V. 47, N 7. P. 1-14.
4. Crick F., Koch C. Some reflections on visual awareness // Cold Spring Harbor symposia on quantitative biology. 1990. V. 55. P. 953-962.
5. Koch C., Crick F. Some Further Ideas Regarding the Neuronal Basis of Awareness // Large-Scale Neuronal Theories of the Brain. Eds. Koch C., Davis J. Cambridge, MA: MIT Press. 1994. P. 93–110.
6. Mountcastle V.B. Perceptual Neuroscience: The Cerebral Cortex // Cambridge, Mass.: Harvard University Press. 1998. 512 p.
7. Сергин В.Я. Нейронные механизмы сознательного восприятия: гипотеза автоотождествления // Лекция на XI Всероссийской научно-технической конференции "Нейроинформатика-2009". Лекции по нейроинформатике. Москва : МИФИ. 2009. С. 35–65.
8. Sergin A.V., Sergin V.Ya. Model of perception: The hierarchy of inclusive sensory characteristics and top-down cascade transfer of excitation // Neural Network World. 2008. V. 18, N 3. P. 227-244.
9. Сергин В.Я., Сергин А.В. Иерархическая модель восприятия без комбинаторного взрыва // Журнал высшей нервной деятельности. 2019. Т.69, № 5. С. 633–658.
10. Сергин В.Я. Автоотождествление и сенсорно-моторное повторение как физиологические механизмы сознания // Журнал высшей нервной деятельности. 2020. Т. 70, № 5. С. 696–720.
11. Sergin V.Ya. Autoidentification and Sensorimotor Rehearsal as a Physiological Mechanisms of Consciousness // Neuroscience and Behavioral Physiology. 2021. V. 51, N 5. P. 648–665.
12. Klatzky R. Human Memory. Structures and Processes. Freeman, 1975.

В.Н. ШАЦНезависимый исследователь, Санкт-Петербург
vlnash@mail.ru

АППРОКСИМАЦИЯ СТРУКТУРЫ ДАННЫХ В ЗАДАЧЕ КЛАССИФИКАЦИИ

В работе введено понятие близости для конечного множества объектов и предложен классификатор, опирающийся на это понятие. Данные объединенной выборки по каждому признаку были аппроксимированы путем отображения на множества упорядоченных пар, содержащих номера объектов с достаточно близкими значениями признака. Тогда содержащаяся в обучающей выборке информация по любому признаку для объектов отдельных классов приближенно представляется в виде множества списков объектов, образующих эти пары. Частота любого элемента списка определяется как сложное событие, а классы объектов – по простейшим формулам теории вероятностей.

Ключевые слова: *новая концепция близости объектов, упорядоченные значения признаков, гранулы информации, диаграммы признаков, ближайшие соседи.*

Введение

Понятие сходства является одним из основополагающих в машинном обучении, поскольку именно оно позволяет сопоставлять наборы данных, которыми описаны объекты обучающей выборки (ОВ), чтобы распознавать объекты разных классов и применить эти знания при разделении объектов тестовой выборки (ТВ) на классы [1]. Обычно мерой сходства двух объектов служит оценка их близости по расстоянию между ними в метрическом пространстве. В статье введено понятие близости для объектов конечного множества, согласно которому значения признака объектов одного класса являются близкими, если разница этих значений достаточно мала. Новый классификатор, который опирается на это понятие близости, реализуется путем изменения архитектуры представления данных. Предложенный классификатор оперирует главным образом не над объектами в целом и многомерными величинами, а только над отдельными признаками объектов и одномерными величинами.

К новому понятию близости объектов привел анализ диаграмм признаков для нескольких баз данных. Он показал, что распределения упорядоченных значений признаков (УЗП) отличаются для объектов каждого

класса и существует принципиальная возможность классификации объектов по частоте ближайших соседей на основе УЗП. Она нашла подтверждение в работе.

Вычислительная процедура основана на аппроксимации распределений признаков объектов объединенной выборки (ОВВ). Она сводится к изменению архитектуры представления исходных данных путем отображения всей совокупности данных ОВВ на множество подмножеств, элементы которых приближенно равны соответствующим значениям признаков. Это отображение, основанное на гранулировании данных [2, 3], было вычислено следующим образом.

Для каждого признака множество УЗП объектов ОВВ разбивается на одинаковое число интервалов (оно служит параметром), в пределах которых разница между значениями признака не учитывается. Списки номеров объектов ОВ одного и того же класса, попадающих в эти интервалы, названы *информационными гранулами*. В соответствии с новым понятием близости объектов все объекты гранулы рассматриваются как ближайшие соседи. Поэтому приближенно считается, что гранула в целом и образующие ее объекты обладают одинаковыми статистическими характеристиками.

Частота гранулы находится как частота сложного события появления определенной упорядоченной пары и класса, которая вычисляется непосредственно по соотношению длин соответствующих подмножеств. Учитывая, что частота появления соответствующего значения признака в определенном классе приближенно равна частоте гранулы, найдем частоту объекта в каждом классе, как среднюю частоту всех признаков объекта, а затем класс объекта, соответствующий максимуму этих частот.

Нам не удалось найти аналогичный концептуальный подход в современной литературе, где анализ ОВ основан на существующем понятии близости объектов и поэтому нацелен на определение характеристик объектов различных классов в целом [4–6]. Однако практическое воплощение предложенного подхода опирается на существующие исследования. Можно считать, что в статье используется новый способ оценки непараметрической регрессии [7], где объединены известные методы ближайших соседей и гранулирования.

Новый метод имеет общие корни с оставшейся незаконченной общей теорией распознавания образов [8]. Согласно теории, информация на разных иерархических уровнях разбивается на множество непересекающихся блоков с выделением простейших стандартных блоков на нижнем уровне. Здесь информационные гранулы играют роль таких блоков.

Существует еще одно пересечение с существующими методами. Состав и частота гранул зависят от упомянутого выше параметра. Поэтому при каждом его значении мы рассматриваем другую аппроксимацию ОВ и фактически анализируем свойства ансамбля выборок, как это принято в методе бэггинга [9].

В статьях автора [10, 11] были рассмотрены задачи классификации, использовавшие аналогичный метод решения, когда еще не были известны свойства УЗП. Множество данных задачи рассматривалось как иерархически организованная система, где были установлены взаимосвязи между признаками, объектами и классами. Кроме того, задачи касались объектов только с количественными или только категориальными признаками, использовали рандомизацию данных, путем введения в значения признаков достаточно малых аддитивных составляющих в виде равномерно распределенных случайных величин [12], а также применяли другие оценки частот признаков (см. ниже).

Было показано в [13], что на основе метода, использованного в этих статьях, можно исследовать процесс восприятия в сенсорных системах животного. Рассматривалась модель обработки информации, хранящейся в мозге животного, для распознавания классов объектов окружающей среды путем поиска их прототипов. Поскольку алгоритмы прежнего и предложенного здесь методов в основном совпадают, то можно считать, что предложенный классификатор реализует биоинспирированный подход.

Простота алгоритма служит важнейшей отличительной особенностью нового классификатора. Она является прямым следствием применения нового понятия близости объектов, согласно которому близкими являются все объекты одной гранулы, класс объекта определяется линейными функциями частоты признаков объектов в отдельных классах, а эти частоты вычисляются по простейшим зависимостям теории вероятности. Другим достоинством алгоритма является его высокая робастность, которая обеспечивается, в соответствии с [14], путем группировки данных в информационные гранулы.

Диаграммы упорядоченных значений признаков

Уточним понятие УЗП, которые составляют основу нового классификатора. Рассмотрим произвольный признак $Z = (z_1, \dots, z_M)^T$, где $s \in (1, M)$ – номера объектов ОВ. Будем считать, что значения признака упорядочены, если объекты будут перенумерованы так, что $z_{(1)} \leq z_{(2)} \leq \dots \leq z_{(M-1)} \leq z_{(M)}$. Тогда объекты класса i , имевшие исходные

номера $s \in \{r_1, \dots, r_{l_i}\}$, получают новые номера $(s) \in \{(r_1), \dots, (r_{l_i})\}$, соответствующие УЗП, где l_i – длина класса i . Очевидно, что для каждого признака объекта соотношения номеров s и (s) будут разными.

В статье были разработаны диаграммы распределения признаков ОБ, которые строятся для любого признака следующим образом. Номера (s) для признаков объектов класса i отображаются в виде точек $((s), i)$. Любая диаграмма имеет общую для всех классов горизонтальную ось $t = (s)/M$, $t \in (0, 1)$ и содержит параллельные ей отрезки прямых $i = \text{const}$, на которых расположены точки, соответствующие номерам (s) при каждом i . На рис. 1 приведены диаграммы признаков для признаков 1 и 5 объектов ОБ задачи Glass [9].




Рис. 1. Диаграммы признака 1 (слева) и признака 5 (справа) ОБ базы данных “Glass”

Очевидно, что совокупность диаграмм визуализирует всю информацию, содержащуюся в ОБ. Анализ диаграмм для этой и других баз данных показал, что распределения УЗП существенно отличаются для каждого класса и признака. Этот результат указывает на принципиальную возможность решения задачи классификации на основе этого свойства УЗП, которую реализует рассматриваемый классификатор.

Постановка задачи и подготовка данных

Рассмотрим следующую задачу классификации. Пусть ОБ представлена множеством $\{(x_s, y_s) | s \in (1, M)\}$ объектов $x_s = (x_{s1}, \dots, x_{sN})^T$, которые принадлежат непересекающимся классам $y_s \in (1, C)$ и имеют $k \in (1, N)$ признаков. В задаче требуется построить алгоритм расчетов и проверить его качество на объектах ОБ и ТВ, принадлежащих единой выборке.

Отметим, что признаки ОБ не являются порядковыми статистиками, так как значения признаков $x^k = (x_1^k, \dots, x_M^k)^T$ имеют разные функции распределения. Поэтому аппарат порядковых статистик [15] не может быть здесь применен.

Некоторые особенности алгоритма требуют учета на этапе подготовки данных. Здесь сами значения признаков играют роль меток, поскольку метод оперирует главным образом с частотами значений признаков. Поэтому значения категориальных признаков опишем непрерывной последовательностью целых чисел. Кроме того, здесь является излишней широко используемая нормализация атрибутов.

Алгоритм решения задачи

При новом понятии близости центральным элементом расчетов становятся подмножества упорядоченных значений каждого признака для объектов отдельных классов. Алгоритм вычислений состоит из двух этапов. На первом этапе изменяется архитектура представления данных, на втором анализируются вероятностные характеристики элементов этой архитектуры.

Первый этап основан на следующей процедуре вычисления отображения произвольного признака k объектов ОБВ. Упорядочим значения признака и разделим весь диапазон его значений на n равных интервалов длиной $h_k = (x_k^{\max} - x_k^{\min}) / (n - 1)$, где n – норма близости, параметр, $x_k^{\min}$ и $x_k^{\max}$ это минимальное и максимальное значения признака соответственно. Обозначим границы интервалов числами последовательности $1, 2, \dots, n$ и перейдем к оценке значения x_k в шкале индексов согласно следующему определению: индекс x_k равен m , если $W(x_k/h_k) = m$, где $W(\cdot)$ – целая часть числа.

В результате при каждом n мы получим отображение множества данных ОБВ на множество упорядоченных пар $\{(k, m) | k \in (1, N), m \in (1, n)\}$. Каждая пара представляет собой список номеров объектов с близкими значениями признака. Если список не является пустым, то он содержит объекты, у которых значения признака $x_k \in [m * h_k, (m + 1) * h_k)$. Только признаки объектов, у которых $x_k = m * h_k$, будут точно описаны с помощью индексов. Значения признаков остальных объектов будут представлены с ошибкой, не превышающей h_k .

Указанное отображение позволяет аппроксимировать произвольный объект $\mathbf{x}_s = (x_{s1}, \dots, x_{sN})^T$ вектором индексов $\mathbf{d}_s = (d_{s1}, \dots, d_{sN})^T$, где d_{sk} – это индекс x_{sk} . Таким образом, мы найдем матрицу индексов, которая является аппроксимацией матрицы данных ОБВ: $\|x_{sk}\| \rightarrow \|d_{mk}\|$, где $s \in (1, K)$, $k \in (1, N)$, $m \in (1, n)$, K – длина ОБВ.

Погрешность аппроксимации будем оценивать величиной, равной отношению максимальной погрешности индексного представления призна-

ка к размаху признака: $\varepsilon = \frac{h_k}{x_k^{max} - x_k^{min}}$. Точность аппроксимации определяется нормой близости согласно соотношению: $\varepsilon = \frac{1}{n-1}$. Матрица индексов представляет значения любого признака с ошибкой, не превышающей ε .

Теперь любой элемент данных ОБ, определяемый упорядоченной тройкой чисел (s, k, i) , будет приближенно описан как элемент множества $\omega_i = \{(k, m), i\}$, которые назовем информационными гранулами (k, m) класса i . Гранулы представляют собой список номеров объектов ОБ определенного класса, которые для любого объекта списка рассматриваются как ближайшие соседи по значению соответствующего признака.

На втором этапе вычислений рассмотрим множество сравнительных частот гранул для разных классов ОБ $\{f_{k,m}^i | k \in (1, N), m \in (1, n), i \in (1, C)\}$. Возможны разные оценки $f_{k,m}^i$ как частоты сложного события появления соответствующей гранулы. В [10, 11] эта частота равнялась отношению количества гранул ω_i к количеству объектов класса i или к общему количеству пар (k, m) всех классов. В настоящей статье частота f_{km}^i принята равной сравнительной частоте ближайшего соседа объекта s по признаку k в классе i :

$$f_{km}^i = \frac{l_{km}^i}{L_i l_{km}}, \quad (1)$$

где l_{km}^i и l_{km} – это количество гранул ω_i и общее число пар (k, m) соответственно, L_i – количество объектов класса i .

Обозначим через $p_i(d_{sk})$ вероятность того, что k -й признак объекта s в классе i имеет индекс m . Поскольку $p_i(d_{sk}) = p(s \in \omega_i | d_{sk} = m)$, то $p_i(d_{sk}) = f_{k,m}^i / M$. Для объектов класса i событие появления вектора $\mathbf{d}^s$ состоит из полной группы независимых событий $d_{s1}, \dots, d_{sN}$. По формуле полной вероятности получим оценку вероятности

$$p_i(\mathbf{d}_s) = \frac{1}{MN} \sum_{k=1}^N f_{k,m}^i. \quad (2)$$

Отметим, что величина $\frac{1}{N} \sum_{k=1}^N f_{k,m}^i$ – это средняя частота гранул (k, m) класса i . Тогда расчетный класс объекта s равен

$$I(s) = \arg \max_{1 \leq i \leq C} p_i(\mathbf{d}_s). \quad (3)$$

Формулы (1) – (3) справедливы для объектов ОБ и ТВ, которые принадлежат единой выборке. Они дают решение при каждом n для объектов ОБ и ТВ (для обучения и классификации). Качество решения будем оценивать частотами ошибок $\nu = \nu(n)$ для обучения и для классификации, возникающих в случае $I(s) \neq y_s$.

Задача сводится к определению области значений нормы близости n , в пределах которой решение будет приемлемо в данной задаче в отношении частот ошибок для обучения и для классификации, вычисленных в соответствии с процедурой скользящего контроля. Поэтому частоты ν вычисляются на некотором множестве $n \in \{2, 3, \dots, J\}$, подмножество которого, как предполагается, содержит нормы близости для данной задачи.

Эффективность классификатора

Эффективность классификатора изучалась на четырех базах данных из репозитория UCI [16]: Breast Cancer, Iris, Letter Image, и Wine. Характеристики баз охватывают довольно широкий диапазон значений количества объектов (150–20 000), признаков (4–16) и классов (2–26); объекты баз имели количественные или категориальные признаки. При каждом n все расчеты выполнялись для 10 вариантов разделения объединенной выборки на ОБ и ТВ согласно процедуре 10-fold cross-validation. В качестве ν были приняты средние значения для рассмотренных вариантов, поскольку полученные распределения частот ошибок нельзя было считать нормальными,

На рис. 2 представлены кривые ν для баз данных, которые идентифицированы первыми буквами в их наименовании. Они построены для $J = 50$, поскольку, как следует из расчетов, при оценке качества решения можно ограничиться значениями $n \in (5, 50)$.




Рис. 2. Кривые частот ошибок ν ОБ (слева) и ТВ (справа) для четырех баз данных

Рисунки показали: значения $\nu \in (0.002, 0.1)$; для каждой базы данных кривые для классификации имеют близкую форму с кривыми для обучения, но идут выше них. Особый интерес представляют кривые при норме близости $25 < n \leq 50$, соответствующей погрешности аппроксимации $0.02 \leq \varepsilon < 0.04$. Здесь значения ν для обучения или для классификации

для любой базы данных приближаются к некоторым константам.

Факт существования указанных констант и их близость для ОБ и ТВ одной и той же базы данных свидетельствует о том, что новая концепция близости объектов вскрывает закономерности распределения классов, а рассмотренный метод является робастным. По-видимому, значения этих констант пропорциональны уровню погрешности, с которой выполняется гипотеза об отличии распределений УЗП для разных классов в данной задаче.

Заключение

В настоящей статье предложен классификатор, основанный на новом понятии близости для объектов конечного множества, согласно которому близость оценивается для каждого признака объектов одного класса, а не для объектов в целом.

Вычислительная процедура основана на следующей аппроксимации распределений признаков объектов ОБВ. Сначала совокупность данных ОБВ отображается на множество упорядоченных пар $\{(k, m)\}$, затем находятся их подмножества для ОБ – информационные гранулы. Они представляют собой списки номеров объектов отдельных классов ОБ, которые рассматриваются как ближайшие соседи по значению признака.

Частоты гранул и любого принадлежащего им объекта определяются как сложное событие из соотношения длин соответствующих подмножеств. Используя эти частоты, мы вычислим классы объектов на основе формулы полной вероятности.

Предложенный классификатор отличается от большинства существующих классификаторов простотой алгоритма, так как он оперирует в основном с одномерными величинами, какими являются значения отдельных признаков, а не многомерными величинами, описывающими объекты в целом.

Результаты расчетов по четырем базам данных свидетельствуют об эффективности и робастности алгоритма. Ошибки классификации и обучения оказались менее 10%. Достаточно высокое качество полученных результатов соответствует выводу о том, что новый классификатор основан на биоинспирированном подходе.

Результаты этого исследования представляются перспективными в отношении применения новой концепции близости объектов, а также нового классификатора. В частности, интерес представляет анализ изменения номеров ошибочно квалифицированных объектов на последовательности значений норм близости как случайного процесса.

Список литературы

1. Luger G.F. Artificial intelligence: structures and strategies for complex problem solving. Boston San Francisco, New York : Addison-Wesley. 2008. 758 p.
2. Yao J., Vasiliacos V., Pedrycz W. Granular Computing: Perspective and Challenges // IEEE Transactions on cybernetics. 2013. V. 43, N 6. P. 1977–1989.
3. Li J., Mei C., Xu W., Quian Y. Concept learning via granular computing: A cognitive viewpoint // Information sciences. 2015. V. 298. P. 447–467.
4. Bishop C. Pattern Recognition and Machine Learning. Berlin : Springer. 2006. 758 p.
5. Hastie T., Tibshirani R., Friedman J. The Elements of Statistical Learning: Data Mining, Inference, and Prediction. Springer. Berlin. 2009. 764 p.
6. Murphy K. Machine Learning. A Probabilistic Perspective. Cambridge. Massachusetts. London : MIT Press, 2012. 1098 p.
7. Tsybakov A.B. Introduction to Nonparametric Estimation. Springer Series in Statistics. Springer. 2009. 221 p.
8. Grenander U. Lectures on pattern theory. V. 1: Pattern Synthesis. New York-Heidelberg-Berlin : Springer-Verlag, 1976. 509 p.
9. Breiman L. Bagging predictors // Machine Learning. 1996. V. 24, N 2. P. 123–140.
10. Shats V.N. Error-Free Training via Information Structuring in the Classification Problem // Journal of Intelligent Learning Systems and Applications. 2019. V. 10. P. 81–92.
11. Шац В.Н. Два простых алгоритма классификации на основе гранулирования информации // Нейроинформатика-2020. XXII Всероссийская научно-техническая конференция : сборник научных трудов. Москва : МИФИ. 2020. С. 127–133.
12. Граничин О.Н., Поляк Б.Т. Рандомизированные алгоритмы оценивания и оптимизации при почти произвольных помехах. Москва : Наука. 2003. 291 с.
13. Shats V.N. The Classification of Objects Based on a Model of Perception // Kryzhanovsky B, Dunin-Barkovski W., Redko V. (eds.) Advances in Neural Computation, Machine Learning, and Cognitive Research. Studies in Computational Intelligence. Moscow : Springer. 2018. V. 736. P. 125–131.
14. Jaynes E.T. Probability Theory: The Logic of Science. Cambridge University Press. New York. 2003. 758 p.
David H.A., Nagaraja H.N. Order Statistics. New York : John Wiley and Sons. 2003. P. 475.
15. Asuncion A., Newman D.J. UCI Machine Learning Repository. Irvine University of California. 2007.

Научное издание

**XXIV МЕЖДУНАРОДНАЯ НАУЧНО-ТЕХНИЧЕСКАЯ
КОНФЕРЕНЦИЯ
"НЕЙРОИНФОРМАТИКА-2022"**

Редакторы и корректоры:

В. А. Дружинина, И. А. Волкова,

О. П. Котова, Н. Е. Кобзева

Компьютерная верстка:

Г.А. Бесхлебнова, З.Б. Сохова,

В.А. Дружинина, Н.Е. Кобзева

Подписано в печать 08.12.2022. Формат 60 × 84 ¹/₁₆. Усл. печ. л. 30,1.

Уч.-изд. л. 28,6. Тираж 25 экз. Заказ № 108.

Федеральное государственное автономное образовательное учреждение
высшего образования «Московский физико-технический институт
национальный исследовательский университет»

141700, Московская обл., г. Долгопрудный, Институтский пер., 9

Тел. (495) 408-58-22, e-mail: rio@mipt.ru

Отпечатано в полном соответствии с предоставленным оригиналом-макетом
ООО «Печатный салон ШАНС» 127412, г. Москва, ул. Ижорская, д. 13, стр. 2