

МИНИСТЕРСТВО НАУКИ И ВЫСШЕГО ОБРАЗОВАНИЯ РОССИЙСКОЙ ФЕДЕРАЦИИ
(МИНОБРНАУКИ РОССИИ)
РОССИЙСКАЯ АКАДЕМИЯ НАУК
МОСКОВСКИЙ ФИЗИКО-ТЕХНИЧЕСКИЙ ИНСТИТУТ
(НАЦИОНАЛЬНЫЙ ИССЛЕДОВАТЕЛЬСКИЙ УНИВЕРСИТЕТ)
НАУЧНО-ИССЛЕДОВАТЕЛЬСКИЙ ИНСТИТУТ СИСТЕМНЫХ ИССЛЕДОВАНИЙ РАН
НАЦИОНАЛЬНЫЙ ИССЛЕДОВАТЕЛЬСКИЙ ЯДЕРНЫЙ УНИВЕРСИТЕТ «МИФИ»
МОСКОВСКИЙ АВИАЦИОННЫЙ ИНСТИТУТ
(НАЦИОНАЛЬНЫЙ ИССЛЕДОВАТЕЛЬСКИЙ УНИВЕРСИТЕТ)
ТРОИЦКИЙ ИНСТИТУТ ИННОВАЦИОННЫХ И ТЕРМОЯДЕРНЫХ ИССЛЕДОВАНИЙ (ТРИНИТИ)
РОССИЙСКАЯ АССОЦИАЦИЯ НЕЙРОИНФОРМАТИКИ
РОССИЙСКАЯ АССОЦИАЦИЯ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА

XXI МЕЖДУНАРОДНАЯ НАУЧНО-ТЕХНИЧЕСКАЯ КОНФЕРЕНЦИЯ

НЕЙРОИНФОРМАТИКА-2019

СБОРНИК НАУЧНЫХ ТРУДОВ

ЧАСТЬ 2

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

МОСКВА
2019

УДК 001(06)+004.032.26(06)
ББК 72я5+32.818я5
М 82

**XXI МЕЖДУНАРОДНАЯ НАУЧНО-ТЕХНИЧЕСКАЯ КОНФЕРЕНЦИЯ
"НЕЙРОИНФОРМАТИКА-2019"** : сборник научных трудов. В 2-х частях.
Часть 2. – Москва : МФТИ, 2019. 213 с. : ил.
ISBN 978-5-89155-323-1 (Ч. 2)
ISBN 978-5-89155-321-7

Сборник научных трудов содержит доклады, включенные в программу XXI Международной научно-технической конференции «НЕЙРОИНФОРМАТИКА-2019», проходившей в г. Москве 7–11 октября 2019 г. Тематика конференции охватывает широкий круг вопросов: искусственный интеллект, глубокое обучение, когнитивные науки и интерфейс «мозг-компьютер», методические вопросы нейроинформатики, теории нейронных сетей, нейробиологии, модели адаптивного поведения и когнитивные исследования, нейросетевые парадигмы и приложения нейроинформатики.

УДК 001(06)+004.032.26(06)
ББК 72я5+32.818я5

ISBN 978-5-89155-323-1 (Ч. 2)
ISBN 978-5-89155-321-7

© Федеральное государственное автономное
образовательное учреждение высшего
образования «Московский физико-
технический институт (национальный
исследовательский университет)», 2019

ОРГАНИЗАТОРЫ КОНФЕРЕНЦИИ

- Министерство науки и высшего образования Российской Федерации (Минобрнауки России)
- Российская академия наук
- Московский физико-технический институт (национальный исследовательский университет)
- Научно-исследовательский институт системных исследований РАН (НИИСИ РАН)
- Национальный исследовательский ядерный университет «МИФИ» (НИЯУ МИФИ)
- Московский авиационный институт (национальный исследовательский университет), МАИ
- Государственный научный центр РФ Троицкий институт инновационных и термоядерных исследований (ГНЦ РФ ТРИНИТИ)
- Российская ассоциация нейроинформатики
- Российская ассоциация искусственного интеллекта

ПРЕДСЕДАТЕЛЬ КОНФЕРЕНЦИИ

Ведяхин А. А. – Первый заместитель Председателя Правления Сбербанка,
Председатель Научно-координационного совета Центра компетенций
по направлению «Искусственный интеллект» МФТИ

ОРГАНИЗАЦИОННЫЙ КОМИТЕТ КОНФЕРЕНЦИИ

Председатель – Гаричев С.Н., проректор по исследованиям и разработкам МФТИ,
Москва

Акад. РАН Бетелин В.Б., НИИСИ РАН, Москва

Акад. РАН Евтушенко Ю.Г., ФИЦ ИУ РАН, Москва

Зам. председателя – Шумский С.А., МФТИ, Москва

Зам. председателя – Тюменцев Ю.В., МАИ, Москва

Зам. председателя – Юдин Д.А., МФТИ, Москва

Панов А.И. – МФТИ, ФИЦ ИУ РАН, Москва

Климов В.В. — НИЯУ МИФИ, Москва

Акопов Э.И. – НИИСИ РАН, Москва

Смирнитская И.А. – НИИСИ РАН, Москва

Сохова З.Б. – НИИСИ РАН, Москва

Трофимов А.Г. – НИЯУ МИФИ, Москва

Пивоваров И.О. – OpenTalks.AI

Ученый секретарь – Бесхлебнова Г.А., НИИСИ РАН, Москва

ПРОГРАММНЫЙ КОМИТЕТ КОНФЕРЕНЦИИ

Председатель – Горбань А. Н. (University of Leicester, UK & ННГУ, Россия)

Сопредседатель – чл.-корр. РАН Крыжановский Б. В. (НИИСИ РАН, Москва)

Сопредседатель – Дунин-Барковский В. Л. (МФТИ, Москва)

Abraham A. – Machine Intelligence Research Labs (MIR Labs), Washington, USA

Baidyk T. – The National Autonomous University of Mexico (UNAM)

Borisyuk R. – Plymouth University, United Kingdom

Cangelosi A. – Plymouth University, United Kingdom

Dosovitskiy A. – Albert-Ludwigs-Universität, Freiburg, Germany

Dudkin A. – United Institute of Informatics Problems of the National Academy
of Sciences of Belarus, Minsk

Golovko V. A. – Brest State Technical University, Belarus

Gorban A. – University of Leicester, Great Britain

Hayashi Y. – Meiji University, Kawasaki, Japan

Husek D. – The Institute of Computer Science of Academy of Sciences
of the Czech Republic, Prague

Izhikevich E. – Braincorporation, San Diego, USA

Jankowski S. – Warsaw University of Technology, Poland

Kecman V. – Virginia Commonwealth University, USA

Kernbach S. – Cybertronica Research, Research Center of Advanced Robotics
and Environmental Science, Stuttgart, Germany

Koprinkova-Hristova P. – Institute of Information and Communication
Technologies, Sofia, Bulgaria

Kussul E. – The National Autonomous University of Mexico (UNAM)

Narynov S. – Alem Research, Almaty, Kazakhstan
Pareja-Flores C. – Universidad Complutense de Madrid, Spain
Prokhorov D. – Toyota Research Institute of North America, USA
Rutkowski L. – Czestochowa University of Technology, Poland
Samsonovich A. V. – George Mason University, USA
Sandamirskaya Y. – Institute of Neuroinformatics, University of Zurich, Switzerland
Sirota A. – Ludwig-Maximilians-Universität, München, Germany
Snasel V. – Technical University Ostrava, Czech Republic
Tikidji-Hamburyan R. – Louisiana State University, USA
Tsodyks M. – Weizmann Institute of Science, Rehovot, Israel
Tsoy Y. – Institut Pasteur Korea, Republic of Korea
Wunsch D. – Missouri S&T
Чл.-корр. РАН Анохин К. В. – НИЦ «Курчатовский институт», Москва
Чл.-корр. РАН Балабан П. М. – ИВНД и НФ РАН, Москва
Бурцев М. С. – МФТИ, Москва
Введенский В. Л. – НИЦ «Курчатовский институт», Москва
Ведяхин А. А. – ПАО «Сбербанк»
Чл.-корр. РАН Величковский Б. М. – НИЦ «Курчатовский институт», Москва
Доленко С. А. – НИИЯФ им. Д.В. Скобелевича МГУ, Москва
Ежов А. А. – ГНЦ РФ ТРИНИТИ, Москва
Жданов А. А. – ИТМиВТ РАН, Москва
Чл.-корр. РАН Иваницкий А. М. – ИВНД и НФ РАН, Москва
Каганов Ю. Т. – МГТУ им. Н. Э. Баумана, Москва
Казанович Я. Б. – ИМПБ РАН - филиал ИПМ им. М.В. Келдыша РАН,
Московская область, Пушкино
Литинский Л. Б. – НИИСИ РАН, Москва
Макаренко Н. Г. – ГАО РАН, Санкт-Петербург
Мишулина О. А. – НИЯУ МИФИ, Москва
Редько В. Г. – НИИСИ РАН, Москва
Акад. РАН Рудаков К. В. – ВЦ РАН им. А.А. Дородницына, Москва
Самарин А. И. – НИИ нейрокибернетики им. А.Б. Когана Южного
федерального университета, Ростов-на-Дону
Терехов С. А. – ЗАО "Связной Логистика", Москва
Трофимов А. Г. – НИЯУ МИФИ, Москва
Тюменцев Ю. В. – МАИ, Москва
Ушаков В. Л. – НИЦ «Курчатовский институт», Москва
Фролов А. А. – ИВНД и НФ РАН, Москва
Чижов А. В. – Физико-технический институт им. А.Ф. Иоффе РАН,
Санкт-Петербург
Шумский С. А. – МФТИ, Москва
Яхно В. Г. – ИПФ 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-2019» представлены доклады по проблемам теории нейронных сетей, нейробиологии, моделям адаптивного поведения, нейросетевому моделированию объектов и систем, обработки статистических данных, временных рядов и изображений и многим другим прикладным задачам нейроинформатики.

Более 200 российских ученых и наших зарубежных коллег направили в оргкомитет конференции результаты своих исследований.

По сложившейся традиции конференцию открывают приглашенные доклады. 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 и инструментами для работы с ними.

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

МАТЕРИАЛЫ 1-Й СТЕНДОВОЙ СЕССИИ

ЧЕРНЫШОВ А.А., КЛИМОВ В.В., БАЛАНДИНА А.И. Анализ зависимостей текста на естественном языке с помощью BiLSTM-сетей	9
БУРАКОВ М.В. Нечеткие оценки пригодности при генетическом синтезе нейроконтроллеров	16
КОШУР В.Д., РОЖКОВ П.И. Реализация мультиагентной системы искусственного интеллекта для решения задачи классификации	24
НЕКРАСОВА Ю.Ю., СУДАРЕВА А.А. Адаптивный сенсомоторный интерфейс «мозг-компьютер» для управления средствами реабилитации	32
СКОБЦОВ Ю.А., ЧЕНГАРЬ О.В. Синтез производственных расписаний на основе многокритериального муравьиного алгоритма	43
ВИТЯЕВ Е.Е. Сознание как комплексное отражение причинно-следственных связей внешнего мира.....	52
PROSKURA A.L., VECHKAROVA S.O., RATUSHNYAK A.S. Dopamine and hippocampal synaptic plasticity	61
PALIKHOVA T.A. Eugene snail: somatosensory maps on the branches of single neuron of land snail.....	67
КРЫЛОВ А.К. Модель формирования колонок нейронов коры как способ метаболической кооперации и конкуренции.....	74
ЯРЕЦ М.Ю., ШАРОВА Е.В., ГАЛКИН М.В., БОЛДЫРЕВА Г.Н., КУЛЕВА А.Ю., ТРОШИНА Е.М., КРОТКОВА О.А. Особенности изменений ЭЭГ при терапевтическом лучевом воздействии у пациентов с менингиомами медиобазальных отделов правого и левого полушарий	82

МАТЕРИАЛЫ 2-Й СТЕНДОВОЙ СЕССИИ

КУЗЬМИНА М.Г., БАСС Л.П., НИКОЛАЕВА О.В. О возможностях моделей глубоких сверточных нейронных сетей и много-агентных систем в задачах обработки гиперспектральных спутниковых изображений.....	91
---	----

АГЕЕВ А.В., СМОЛИН В.С., СОКОЛОВ С.М. Исследование применимости нейронной сети для управления сферическим приводом	100
СОКОЛОВА Е.С., ТЕЛЬНЫХ А.А. Кластеризация и идентификация грозовых конвективных ячеек в мезомасштабных системах.....	109
БЕРГАЛИЕВ Т.К., МАЗУРОВ М.Е. Об эффективности государственной поддержки в области разработки и внедрения нейрообразовательных технологий	118
ШЕЛОМЕНЦЕВА И.Г. Применение системы нейро-нечеткой классификации Nefclass для распознавания изображений анализов мокроты, окрашенной по методу Циля-Нильсена	125
ДЕРЯБИН В.В. Расчёт широты места судна на основе нейронной сети	132
АЛЕКСЕЕВ С.В., КОНЕВА А.Д., СЕРЕДА Я.А. Сегментация ЭКГ нейронными сетями: ошибки и их исправление..	141
КОРОТКОВ А.Г., ОСИПОВА М.А., ЗАКС М.А., ОСИПОВ Г.В. Ансамбль возбуждающе связанных нейроноподобных элементов....	151
ТЕЛЬНЫХ А.А., НУЙДЕЛЬ И.В., ШЕМАГИНА О.В. Биоморфная модель кортикальной колонки для семантического анализа изображений	159
БОЛОТОВ М.И., ОСИПОВ Г.В. Коллективная динамика импульсно-связанных нейроноподобных элементов.....	169
КРАСНОВ М.М., СМОЛИН В.С. Локальная кривизна и точность нейросетевой аппроксимации	175
МИКРЮКОВ А.А., МАЗУРОВ М.Е. Решение задачи классификации на основе комитета избирательных нейросетей	186
ЧЕРНЫШОВ А.В., ЛОБОВ С.А. Хеббовское и конкурентное обучение в импульсных нейронах	195

WORKSHOP ОТ КОМПАНИИ INTEL

ДЕМИДОВСКИЙ А. В. Особенности программных и аппаратных средств для оптимизации инференса обученных нейронных сетей в рамках среды OPENVINO.....	204
--	-----

МАТЕРИАЛЫ 1-Й СТЕНДОВОЙ СЕССИИ

А. А. ЧЕРНЫШОВ, В. В. КЛИМОВ, А. И. БАЛАНДИНА

Национальный исследовательский ядерный университет «МИФИ», Москва

a-chernyshov@protonmail.com

АНАЛИЗ ЗАВИСИМОСТЕЙ ТЕКСТА НА ЕСТЕСТВЕННОМ ЯЗЫКЕ С ПОМОЩЬЮ BiLSTM-СЕТЕЙ*

Рассматривается идея проведения многоступенчатого процесса построения поискового образа запроса на естественном языке для использования в системе семантического поиска. Современные методы и инструменты обработки естественного языка широко используются в области машинного перевода. Исследования в области поисковых систем и семантического поиска в основном сосредоточены на хранении данных и дальнейшем анализе. Большинство поисковых систем используют огромное количество ранее накопленных пользовательских запросов для прогнозирования результатов поиска, не принимая во внимание это намерение пользователя путем качественной обработки запроса. Предлагаемый подход основан на выделении максимального количества информации из исходного запроса путем проведения синтаксического и семантического анализа, а также применении приемов синонимичного расширения. В данной статье описывается первый этап процесса построения модели поискового запроса, основанный на выделении синтаксических зависимостей из исходного предложения.

Ключевые слова: анализ и обработка естественного языка, информационный поиск, анализ зависимостей, BiLSTM-нейронные сети.

Введение

На данный момент, большинство современных поисковых систем работает по принципу выделения ключевых слов из поискового запроса и дальнейшего сопоставления с существующим поисковым индексом. Этот

* Работа выполнена при финансовой поддержке гранта Президента Российской Федерации для государственной поддержки молодых российских ученых – кандидатов наук (№ гранта МК-6888.2018.9). Разработанные модели созданы с использованием результатов НИР, проводимых в рамках Договора (Соглашения) 12686ГУ от 24.04.2018 о предоставлении гранта по Программе "Участник молодежного научно-инновационного конкурса (УМНИК) " Фонда содействия развитию малых форм предприятий в научно-технической сфере.

подход не учитывает семантику и отношения между словами в исходном запросе. Потеря скрытых зависимостей может привести к плохой релевантности результатов поиска. Тем не менее данный подход имеет место в том случае, когда имеющийся поисковый индекс огромен, а поисковая система руководствуется также профилем пользователя, который составляется сторонними системами.

Работая в строго определенной области, например, внутри конкретной организации, данный подход не выглядит состоятельным, поскольку огромный индекс отсутствует, а профиль пользователя никак не определен. Таким образом, работая над системой семантического поиска, мы не можем игнорировать семантику, поскольку использование простых ключевых слов приведет к низкой релевантности поисковой выдачи.

В рамках данной работы предлагается использование доменных онтологий для хранения поискового индекса и методы обработки естественного языка для построения иерархического изображения поискового запроса с сохранением семантических зависимостей для сопоставления и поиска на графе онтологий. Одной из задач является разработка адекватной модели поискового запроса, то есть поискового образа запроса, для дальнейшего использования в системе семантического поиска. Для этого необходимо решить ряд проблем, связанных с зависимостями между словами на уровне фраз, проблемами определения синонимов в контексте исходных слов и фраз и мерами их близости, определения контекста поиска и поисковых намерений пользователя в контексте области поиска.

В данной статье рассматривается одна из перечисленных выше проблем, связанных с зависимостями между словами, также представлен разработанный алгоритм, созданный на основе классического разбора зависимостей.

Модели и методы

Один из способов выделения зависимостей внутри фразы – построения дерева зависимостей [1]. Здесь может быть два варианта – выделение зависимостей на уровне слов и на уровне фраз. Зависимости на уровне фраз хорошо подходят для понимания структуры предложения. Для того чтобы понимать структуру конкретной фразы внутри предложения, наиболее подходят грамматики на основе зависимостей.

В синтаксическом дереве зависимостей корнем, как правило, является глагол или любое другое слово, обозначающее действие. На втором ярусе, как правило, находятся объект и субъект действия, на более низких ярусах – характеристики объекта и субъекта и различные ограничители (время, количество, свойства и т.д.).

Все связи в дереве являются помеченными специальными POS-метками. Исходя из типа метки, можно отбрасывать незначимые термины,

например, тег CASE объединяет предлоги, союзы и другие незначимые части речи, которые могут быть отброшены из рассмотрения.

Таким образом, поисковому запросу можно легко сопоставить иерархическую структуру с явно выделенными зависимостями между значащими терминами.

Для построения соответствующей модели используется анализатор shift-reduce [2]. Для обучения используется рекуррентная нейронная сеть LSTM с одним скрытым слоем. В качестве данных для обучения используется заранее размеченный корпус русскоязычных текстов. В качестве функции потерь используем кросс-энтропию с L_2 регуляризацией: $\mathcal{L}(\sigma) = -\sum_{i,j} \log(y_{ij})$.

Конечная цель – получить последовательность действий – shift (left-arc, right-arc), reduce, по которой можно восстановить древовидную структуру [3], как показано на рис. 1.

Классическая архитектура нейронной сети LSTM описывается набором следующих формул:

$$\begin{aligned} f_t &= \sigma_g(W_t x_t + U_f h_{t-1} + b_f) - \text{вектор активации вектора забывания,} \\ i_t &= \sigma_g(W_t x_t + U_i h_{t-1} + b_i) - \text{вектор активации входа,} \\ o_t &= \sigma_g(W_o x_t + U_o h_{t-1} + b_o) - \text{вектор активации выхода,} \\ c_t &= f_t \circ c_{t-1} + i_t \circ \sigma_c(W_c x_t + U_c h_{t-1} + b_c) - \text{вектор состояния,} \\ h_t &= o_t \circ \sigma_h(c_t) - \text{выходной вектор.} \end{aligned}$$

Для оценки полученной модели были использованы меры precision, recall и среднегармоническая F-мера. Получаемую на выходе модель можно представить в виде графа:

$$G = \langle X, A \rangle,$$

где $X = \{x_1, x_2, \dots, x_n\}$ – слова входного поискового запроса

$A = \{a_1, a_2, \dots, a_n\}$ – построенные связи между словами вида

$$a_i := x_i \xrightarrow{\text{pos}} x_j.$$

Полученную модель можно использовать для поиска по онтологии. Формально онтологию можно представить в виде

$$O = \langle I, C, P, O \rangle,$$

где $I = \{o_1, o_2, \dots, o_n\}$ – объекты, или сущности предметной области,

$C = \{c_1, c_2, \dots, c_n\}$ – классы,

$P = \{p_1, p_2, \dots, p_n\}$ – характеристики классов,

$O = \{o_1, o_2, \dots, o_n\}$ – операторы между классами.




Рис. 1. Иллюстрация работы алгоритма shift-reduce

Первым шагом поискового алгоритма является сопоставление корня исходного дерева с типом связи на онтологии [4]. Так как связи в онтологии являются однозначно именованными, тогда как в исходном запросе они могут сильно различаться. Для того чтобы сопоставить корень с типом связи, необходимо определить степень похожести между двумя словами – имя связи на графе и корень дерева [5].

Для этого используется поиск по векторному пространству связей, для определения меры похожести используется косинусная мера:

$$sim = \min_{i=1,n} \left(\frac{\sum_{v=1}^k x_{iv} o_{i,v}}{\sqrt{\sum_{v=1}^k x_{iv}^2} \sqrt{\sum_{v=1}^k o_{i,v}^2}}, \frac{\sum_{v=1}^k x_{iv} c_{i,v}}{\sqrt{\sum_{v=1}^k x_{iv}^2} \sqrt{\sum_{v=1}^k c_{i,v}^2}} \right).$$

Как только найдена наиболее правдоподобная связь в онтологии, необходимо найти два типа вершин, которые она связывает [6]. Для этого также применяется поиск похожих слов на графе для вершин типа субъект и объект действия. Как только необходимая связь найдена, определяются условия в зависимости от типа связи. Это могут быть временные условия, локационные или характеристические.

Результаты

Для оценки модели, полученной в результате работы синтаксического анализатора, используются классические метрики – точность (precision), полнота (recall) и F-мера [7]:

$$Rec = \frac{|S_{train} \cap S_{parsed}|}{|S_{train}|}$$

$$Prec = \frac{|S_{train} \cap S_{parsed}|}{|S_{parsed}|}$$

$$F = 2 \frac{prec \times rec}{prec + rec}$$

Помимо стандартных метрик рассматриваются также дополнительные меры оценки точности анализатора. Labeled precision – относительное количество правильно распознанных пар-меток узлов в выходных данных анализатора. Labeled recall – относительное количество меток узлов-пар из обучающей выборки, получаемое в результате работы анализатора. Данные метрики используются для расчета таких мер, как LAS (labeled attachment score) – относительного количество правильно определенных пар с учетом синтаксической метки и UAS (unlabeled attachment score) – относительного количество правильно определенных пар без учета синтаксической метки. Помимо перечисленных выше метрик, также используется метод leaf-ancestor (LA), который сравнивает путь между узлами (от конечных узлов до корня) выходных данных синтаксического анализатора и путь в соответствующем предложении в тестовой выборке [8]. Сходство путей рассчитывается с помощью расстояния Левенштейна:

$$lev_{a,b}(i,j) = \begin{cases} \max(i,j), & \text{if } \min(i,j) = 0 \\ \min((lev_{a,b}(i-1,j) + 1), (lev_{a,b}(i,j-1) + 1), (lev_{a,b}(i-1,j-1) + 1)) & \text{otherwise} \end{cases}$$

Для обучения нейронной сети, являющейся ядром анализатора, мы использовали выборку предложений в формате CoNNL-U для русского языка - UD_Russian-SynTagRus. Он содержит 61 889 предложений и 1 106 290 слов. В таблице 1 приводится результат расчета описанных выше метрик в сравнении с другими известными анализаторами [9].

Таблица 1

Сравнение анализаторов

	LAS		LA		UAS		F	
	train	test	train	test	train	test	train	test
MALT	69,73	67,30	78,92	75,77	76,50	71,74	75,12	74,54
SyntaxNet	72,09	69,58	81,59	78,34	79,09	74,17	77,66	77,07
SNNDP	70,41	67,96	79,69	76,51	77,25	72,44	75,85	75,27
spaCy	68,07	65,70	77,04	73,97	74,68	70,04	73,33	72,77
Described parser	76,12	73,47	86,16	82,72	83,51	78,32	82,00	81,38

В результате использования BiLSTM нейронной сети в качестве ядра анализатора средняя точность распознавания зависимостей заметно увеличилась, как показано на рис. 2.




Рис. 2. Сравнение анализаторов

Все перечисленные выше метрики показывают способность синтаксического анализатора правильно распознавать метки дуг и теги [2]. Мы также вычислили процент правильно распознанных тегов части речи и обнаружили, что разница между анализаторами незначительна. Например, точность SyntaxNet для способности распознавать теги ADJ, NOUN и VERB составляет 93,2450, 91,4477 и 83,7365 соответственно, полученный анализатор – 92,3709, 90,8152 и 85,7920 соответственно.

Выводы

В данной статье описан первый этап многоступенчатого процесса обработки поисковых запросов. Общая схема работы алгоритма построения внутренней структуры запроса приведена на рис. 3.

Данный процесс также содержит и другие шаги – расширение синонимов, распознавание контекста и пользовательских целей, распознавание именованных сущностей и общую проверку грамматики. Тем не менее синтаксический анализ является важнейшим шагом в обработке естественного языка и в том числе обработке пользовательских запросов.




Рис. 3. Процесс обработки поискового запроса

Дальнейшие задачи включают разработку методов и алгоритмов извлечения пользовательских намерений с помощью семантического отображения картирования и синтаксического анализа, расширения синонимичных отношений с использованием векторных пространств слов [5].

Список литературы

1. Kubler S., McDonald R., Nivre J. Dependency parsing // Synthesis Lectures on Human Language Technologies. 2009. Vol. 1, No. 1. P. 1-127.
2. Balandina A., Kostkina A., Chernyshov A., Klimov V. Dependency Parsing of Natural Russian Language with Usage of Semantic Mapping Approach // Procedia Computer Science. 2018.
3. Nivre J. Algorithms for deterministic incremental dependency parsing // Computational Linguistics. 2008. Vol. 34, No. 4. P. 513-553.
4. Chernyshov A., Balandina A., Kostkina A., Klimov V. Intelligence Search Engine and Automatic Integration System for Web-Services and Cloud-Based Data Providers Based on Semantics // Procedia Computer Science. 2016.
5. Chernyshov A., Balandina A., Klimov V. Intelligent Processing of Natural Language Search Queries Using Semantic Mapping for User Intention Extracting // Advances in Intelligent Systems and Computing. 2019.
6. Nivre J. Transition-Based Parsing. 2013.
7. Kostkina A., Bodunkov D., Klimov V. Document Categorization Based on Usage of Features Reduction with Synonyms Clustering in Weak Semantic Map // Procedia Computer Science. 2018.
8. Collobert R., Weston J. A unified architecture for natural language processing // 25th International Conference on Machine Learning – ICML '08. 2008. Vol. 20.
9. Nivre J. An efficient algorithm for projective dependency parsing // Proceedings of the 8th International Workshop on Parsing Technologies. 2003.

М. В. БУРАКОВ

Санкт-Петербургский государственный
университет аэрокосмического приборостроения
bm@sknt.ru

НЕЧЕТКИЕ ОЦЕНКИ ПРИГОДНОСТИ ПРИ ГЕНЕТИЧЕСКОМ СИНТЕЗЕ НЕЙРОКОНТРОЛЛЕРОВ

Рассматривается задача выбора функции пригодности при генетическом синтезе нейроконтроллера. Предлагается использовать нечеткие оценки пригодности, позволяющие более точно сравнивать различные варианты движения системы и ускорить процесс поиска решения. Приводятся результаты вычислительного эксперимента в *Simulink MatLab* по определению параметров нейроконтроллера для нелинейного динамического объекта, которые подтверждают практическую полезность предлагаемого подхода при синтезе нейроконтроллеров для широкого круга систем управления.

Ключевые слова: управление, обучение, нейроконтроллер, генетический алгоритм.

Введение

Искусственная нейронная сеть (НС) является универсальным настраиваемым нелинейным звеном, которое может выступать в качестве регулятора динамического объекта – нейроконтроллера.

Настройка параметров нейроконтроллера является, по существу, задачей оптимизации, сложность которой зависит от вида целевой функции. Для унимодальной целевой функции хорошие результаты обеспечивает алгоритм обратного распространения ошибки [1, 2]. В случае сложной целевой функции возникает задача глобальной оптимизации, которая может быть решена с помощью генетического алгоритма (ГА) [3–5].

При генетическом синтезе параметры нейроконтроллера кодируются хромосомой. Набор хромосом образует популяцию, которая изменяется под действием генетических операторов отбора, скрещивания и мутации [4]. Операция отбора использует значение функции пригодности, которое связано с каждой хромосомой, и соответствует качеству решения, обеспечиваемого этой хромосомой. При синтезе нейроконтроллера функция пригодности должна описывать соответствие параметров эталонного переходного процесса $y(t, \mathbf{P})$ и процесса $y(t)$, полученного при использовании конкретной хромосомы (рис. 1, где $g(t)$, $e(t, \mathbf{P})$ и $u(t)$ – соответственно уставка, ошибка выхода и сигнал управления, $\mathbf{P}$ – параметры регулятора).




Рис. 1. Генетическое обучение нейроконтроллера

Нейроконтроллер может быть реализован на базе НС прямого распространения, так что вектор $\mathbf{P}$ кодирует веса межнейронных связей. Ошибка $e(t, \mathbf{P})$ относится к одному моменту времени, но значение функции пригодности должно соответствовать всему переходному процессу, обеспечиваемому хромосомой.

Постановка задачи

Рассмотрим подход к проектированию, который реализован в пакете MatLab, содержащем инструментальное средство Simulink Design Optimization [6]. При проектировании регулятора системы можно описать «коридор», в котором должна находиться кривая переходного процесса для динамической системы, заданной дифференциальными уравнениями и содержащей варьируемые параметры.

Могут быть заданы границы «коридора» – функции времени $y_1(t)$ и $y_2(t)$ такие, что

$$y_1(t) < y_2(t), \quad \forall t \in [0, T].$$

Пусть вектор параметров $\mathbf{P}$ должен быть выбран таким образом, чтобы

$$y_1(t) \leq y(t, \mathbf{P}) \leq y_2(t), \quad \forall t \in [0, T].$$

Иначе говоря, в результате настройки параметров кривая $y(t, \mathbf{P})$ должна находиться в пределах заданного динамического «коридора» на плоскости (рис. 2).




Рис. 2. Описание границ для переходного процесса

Для решения поставленной задачи может быть введена в рассмотрение функция $e(t, \mathbf{P})$, определяющая меру выхода кривой $y(t, \mathbf{P})$ за пределы коридора. Рассмотрим набор моментов времени t_i (рис. 2) и опишем функцию ошибки в виде

$$e(t_i, \mathbf{P}) = \begin{cases} 0, & y_2(t_i) \leq y(t_i, \mathbf{P}) \leq y_1(t_i); \\ y(t_i, \mathbf{P}) - y_1(t_i), & y(t_i, \mathbf{P}) > y_1(t_i); \\ y_2(t_i) - y(t_i, \mathbf{P}), & y(t_i, \mathbf{P}) < y_2(t_i). \end{cases} \quad (1)$$

Общая мера выхода за пределы коридора:

$$E(\mathbf{P}) = \sum_{i=1}^N e(t_i, \mathbf{P}), \quad i = \overline{1, N}.$$

Оптимизационная задача формулируется в виде: $E(\mathbf{P}) \rightarrow \min$.

Таким образом, функция $E(\mathbf{P})$ задается через значение функционала, который вычисляется после моделирования движения системы при заданных параметрах.

Уменьшая ширину «коридора», можно прийти к рассмотрению эталонного процесса $y^*(t)$, так что

$$e_i(\mathbf{P}) = y^*(t_i) - y(t_i). \quad (2)$$

Тогда общая ошибка может быть описана с помощью следующих вариантов:

$$E_1(\mathbf{P}) = \sum_{i=1}^N |e_i(\mathbf{P})|, \quad E_2(\mathbf{P}) = \sum_{i=1}^N (e_i(\mathbf{P}))^2, \quad i = \overline{1, N}.$$

Можно показать, что варианты E_1 и E_2 допускают качественное несоответствие эталонной и реальной траекторий.

Например, на рис. 3 показаны различные переходные процессы: a и b – варианты при различных параметрах регулятора, c – эталонный переходный процесс.




Рис. 3. Различные реакции на скачок в динамической системе

По критериям $E_1(\mathbf{P})$ и $E_2(\mathbf{P})$ получают примерно одинаковые оценки, в то время как качественно кривые a и c соответствуют устойчивому переходному процессу, а кривая b – неустойчивому. Иначе говоря, с точки зрения оптимальной настройки нейроконтроллера кривая a должна иметь лучшую оценку пригодности, чем кривая b .

Нечеткие оценки пригодности

Понятие нечеткой траектории введено в [7] с целью оценки близости выходов объекта и модели, которые должны находиться в «коридоре», заданном функциями принадлежности.

Рассмотрим функцию ошибки в виде

$$E_3(\mathbf{P}) = \min(\mu_A(e_i(\mathbf{P}))), \quad i = \overline{1, N},$$

где μ – функция принадлежности нечеткого множества A – «Малая ошибка» (рис.4).




Рис. 4. Нечеткое описание малой ошибки

Гауссова функция принадлежности (рис. 4) максимизируется только при непосредственной близости эталонной и реальной траектории ($e \approx 0$) и быстро убывает при их отклонении друг от друга.

В табл. 1 приведено сравнение различных функций ошибки для вариантов моделирования, показанных на рис. 3.

Таблица 1

Сравнение различных оценок пригодности

Вариант сравнения	Функция пригодности		
	E_1	E_2	E_3
$a - c$	1.16	0.20	0.43
$b - c$	1.15	0.23	0.2

Как показывает табл. 1, по критериям E_1 и E_2 переходные процессы a и b практически равноценны. Напротив, по критерию E_3 устойчивый переходный процесс a более чем вдвое предпочтительнее неустойчивого процесса b . Поскольку при использовании ГА по умолчанию рассматривается минимизация целевой функции и $0 \leq E_3 \leq 1$, вместо максимизации E_3 можно рассматривать минимизацию $E_4 = 1 - E_3$ или $E_4 = 1 - (E_3)^2$.

Пример моделирования

Основное назначение предлагаемой методики заключается в ускорении процессов генетической настройки нейроконтроллеров, поэтому рассмотрим задачу синтеза системы управления для конкретного объекта.

Пусть объект управления описывается моделью Гаммерштейна с динамической линейной частью и статической нелинейной частью.

В качестве регулятора будем использовать 2-слойную НС прямого распространения с тремя нейронами 1-го слоя (активационная функция

tansig) и нейроном выходного слоя с линейной активационной функцией (рис. 5).




Рис. 5. Структура нейроконтроллера

Блок-схема моделирования процесса настройки нейроконтроллера в *MatLab Simulink* представлена на рис. 6.




Рис. 6. Обучение нейроконтроллера

Массивы *simout* служат для получения ошибок моделирования и построения оценок пригодности [4].

На рис. 7 показан пример реализации генетического обучения с помощью инструмента *GA tool MatLab*.




Рис. 7. Изменение оценок пригодности в процессе обучения

На рис. 8 приведен результат обучения нейроконтроллера, хромосома включает в себя 12 генов – весов межнейронных связей.




Рис. 8. Реакция на скачок: *a* – система без регулятора, *b* – эталонный процесс, *c* – система с регулятором

Выводы

Генетический алгоритм является стохастическим методом оптимиза-

ции, поэтому скорость поиска решения с его помощью зависит от начального распределения популяции. Если одна из хромосом оказывается в окрестности субоптимального решения, то популяция быстро стягивается к этой точке. Эта особенность затрудняет непосредственное сравнение различных критериев отбора хромосом. Однако, специфика генетической настройки нейроконтроллера заключается в том, что функция пригодности хромосомы должна оценивать форму соответствующего переходного процесса. Использование нечетких оценок пригодности позволяет отсекаать заведомо неадекватные варианты хромосом, заменяя их случайными значениями. Тем самым поиск направляется в новые области, где может быть найдено решение. Это особенно важно при большом количестве параметров регулятора.

Проведенный вычислительный эксперимент в *Simulink MatLab* показал, что задача генетического синтеза нейроконтроллера может быть решена достаточно точно, поэтому рассмотренный подход может иметь важное практическое значение.

Список литературы

1. Hagan M.T., Demuth H.B. Neural networks for control // Proceedings of the 1999 American Control Conference. San Diego: CA, 1999. P. 1642–1656.
2. Галушкин А. И. Основы нейроуправления / А. И. Галушкин // Приложение к журналу «Информационные технологии». 2002, № 10. С. 2–16.
3. Бураков М.В. Синтез нейронного регулятора // Изв. Академии наук. Теория и системы управления. 1999. №3. С.140-145.
4. Бураков М.В. Генетический алгоритм: теория и практика. Санкт-Петербург, ГУАП. 2008. 164 с.
5. Yang X. S. Engineering optimization: an introduction with metaheuristic applications. Hoboken, NJ, USA: Wiley; 2010.
6. Robust Control Toolbox 3: User's guide / G.J. Balas, R.Y. Chiang, A. Packard, M.G. Safonov. Natick (Mass.): The MathWorks, Inc., 2010. – 178 p.
7. Бураков М.В., Попов О.С. Элементы искусственного интеллекта в проблеме управления сложным динамическим объектом // Автоматика и телемеханика. 1997. № 8. С. 118-124.

В.Д. КОШУР, П.И. РОЖКОВ

Институт космических и информационных технологий СФУ, г. Красноярск
vkoshur@sfu-kras.ru, prozskov@gmail.com

РЕАЛИЗАЦИЯ МУЛЬТИАГЕНТНОЙ СИСТЕМЫ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА ДЛЯ РЕШЕНИЯ ЗАДАЧИ КЛАССИФИКАЦИИ

Рассматривается задача проектирования и разработки мультиагентной системы, которая позволяет гибко решать задачу классификации. Данный подход базируется на использовании агентов, которые находятся в собственном изолированном пространстве и формально ничего не знают друг о друге, но между ними происходит «общение» – передача информации о накопленных знаниях. Каждый агент решает собственную задачу и является частью общей системы агентов. Помимо представленного способа построения мультиагентных систем искусственного интеллекта, предлагаются способы улучшения и модернизация системы, сравнение с классическим подходом. Стоит отметить, что такая мультиагентная система является гибкой и реализует микросервисную архитектуру, что позволяет использовать ее для тренировки и решения широкого спектра задач классификации.

Ключевые слова: мультиагентные системы, микросервисы, искусственный интеллект.

Введение

Рассмотрим типичный подход к построению систем искусственного интеллекта в рабочей среде. Как правило, такие системы представляют собой некоторый программный сервер, который «принимает» запросы и производит ответы. Внутри такого сервера находится алгоритм – обученная модель, которая способна решать некоторый класс необходимых задач. Все, что требуется пользователю, – обратиться к серверу и получить от него ответ. Что потребуется выполнить разработчику или исследователю в том случае, когда необходимо добавить новый класс для распознавания или усилить распознавание класса в текущей модели? Потребуется перетренировка модели, которая в целом может породить новые проблемы в других классах. Данная процедура затратна с точки зрения времени, потому что переобучение новой модели займет дополнительное время. Данную проблему можно решить, используя мультиагентный подход.

В общем случае агент – это элемент, который воспринимает свое среду с помощью датчиков и воздействует на нее с помощью исполнительных

механизмов [1]. Важной особенностью агентов является их автономность и коллегиальность [2]. В данной работе мы комбинируем понятие *агент* с понятием *микросервис*. Так, Сэм Ньюмен определил, что микросервисы – это небольшие автономные, совместно работающие программы [3]. Микросервисный подход имеет ряд преимуществ перед монолитными системами:

1. Технологическая разнородность – отсутствие привязки к определенным технологиям и инструментам.
2. Устойчивость – благодаря распределенности достигается отсутствие «бутылочных горлышек» системы.
3. Простота развертывания – можно вносить изменения в отдельные сервисы, не затрагивая систему в целом.
4. Оптимизация с целью последующей замены.

Агент может общаться с другими агентами, проявлять независимое поведение, которое может рассматриваться как следствие его знаний, взаимодействия с другими агентами целей, которых он должен достичь [4].

Цель данной работы — продемонстрировать подход, к построению современных систем искусственного интеллекта, которые реализуют мультиагентную архитектуру.

Данная работа является развитием исследований [5]. Дополнена структура агента и добавлены новые.

Постановка задачи и описание системы

Будем предполагать, что система должна решать задачу классификации по N признакам. Признаки могут быть бинарными, целочисленными. Она не должна быть привязана к определенной задаче и определенным наборам данных (обучающей выборке).

Введем следующие понятия:

1. Классификатор – основной элемент системы. Хранит в себе идентификатор, ссылку на модель, ссылку на набор данных, список гиперпараметров, таблицу с результатами распознавания и статус доступности.
2. Маршрутизатор – хранит в себе список доступных агентов, принимает запросы, отправляет агентам запросы типа «обещание». Такие запросы гарантируют, что ответ вне зависимости от результата вернется маршрутизатору и он будет «знать» о текущем состоянии агента-классификатора.
3. Хранитель наборов данных – используется для хранения наборов данных, исключения создания разнородных копий одних и тех же данных. Отправляет обучающие выборки агентам при запросе на обучение.

4. Сборщик – принимает запрос от маршрутизатора, в котором есть информация об идентификаторах агентов, которые используются в данный момент для определенной задачи классификации. Не отвечает клиенту до тех пор, пока все ожидаемые агенты не отправят свои ответы.
5. Наблюдатель (супервизор) – собирает информацию об ответах агентов-классификаторов для последующей обработки пользователем.

Как видно из описания агентов, каждый агент реагирует только на те события, которые он *должен обрабатывать*, и делает *минимум* действий. Это максимально упрощает процесс работы с агента. На рис. 1 приведена общая схема системы.




Рис. 1. Упрощенная схема мультиагентной системы

Подробное описание каждого агента

Агент – классификатор. Рассмотрим основные компоненты агента:

1. Идентификатор – используется для обращения к агенту, хранится в маршрутизаторе.
2. Ссылка на модель – используется для идентификации используемой модели (агент изначально не знает, какую именно модель ему использовать).
3. Ссылка на набор данных – агент имеет метку об использованном в нем наборе данных. Данная ссылка позволит идентифицировать используемые обучающие множества.
4. Список гиперпараметров – является важной составляющей агента, с помощью данного списка происходит инициализация модели.

5. Таблица с результатами распознавания – используется для идентификации ошибок.
6. Статус доступности – используется при маршрутизации.

Стоит отметить, что важной особенностью такого типа агентов является то, что их можно создать необходимое количество копий для решения одной и той же задачи, если это потребуется.

Маршрутизатор. Является важной частью системы и занимается разбиением задачи на подзадачи, но не умеет их решать [6]. Принимает запросы от клиента, отправляет запросы агентам классификаторам. Использование данного агента позволяет сохранять работоспособность всей системы благодаря отправке запросов типа «обещание», что гарантирует доставку ответов обратно. Кроме того, он выступает балансировщиком нагрузки и не позволяет отправлять сразу несколько запросов в одного агента или игнорирует загруженных агентов, отправляя запросы в дублирующие сервисы.

Хранитель наборов данных. Хранит различные наборы данных, которые пользователь отправляет в систему для обучения и тестирования классификаторов. Каждый набор имеет уникальный идентификатор и сами обучающие множества.

Сборщик. Сборщик ожидает ответа от всех агентов классификаторов, что позволяет избежать эффекта «гонок», когда все классификаторы не вернули ответы, а пользователь уже получил решение, которое может быть неверным.

Наблюдатель. Хранит структуры данных вида: дата/время, идентификатор классификатора, входные данные, выходные данные. Такой агент позволяет анализировать производительность классификаторов и делать выводы пользователю.

Схема взаимодействия агентов типа «классификатор», «маршрутизатор» и «сборщик» отображена на рис. 2 ниже.




Рис. 2. Взаимодействие классификатора, маршрутизатора и сборщика

Реализация системы

В качестве базы для каждого агента мы использовали Docker. Docker – это программное обеспечение, которое позволяет использовать контейне-

ризацию и упаковать приложение со всеми библиотеками и зависимостями. Схема работы Docker изображена на рис. 3.




Рис. 3. Схема контейнеризованного приложения в Docker [7]

Программная структура агента классификатора внутри контейнера состоит из трех основных компонентов:

1. Веб-сервер, который реализует API (программный интерфейс приложения), принимает запросы и в зависимости от типа запроса возвращает ответ или запускает модель для задачи классификации или обучения.
2. База данных, которая хранит каждое обращение к веб-серверу, используется для последующего анализа поведения агента.
3. Сама модель, которая, по своей сути, является скриптом с набором весов и определенных характеристик. Модель может быть реализована любым из подходящих методов. В нашем случае использовалась библиотека Scikit-learn [8]. Она позволяет достаточно быстро строить и использовать модели машинного обучения.

На рис. 4 изображена структура агента классификатора.



Рис. 4. Структура классификатора

Задача из реальной жизни

В качестве тестовой задачи мы определяли возникновение проблем с сердцем, используя Heart Disease Data Set. [9] Этот набор данных из 303 записей, каждая из которых включает в себя 14 атрибутов, ниже перечислены основные:

1. Возраст.
2. Пол.
3. Тип боли в груди.
4. Артериальное давление.
5. Холестерин.
6. Уровень сахара в крови натощак.
7. Результаты ЭКГ.
8. Максимальная частота сердечных сокращений.
9. Стенокардия, вызванная упражнениями.
10. Целевая переменная.

Используя эти данные, требуется построить модель, которая будет определять наличие проблем с сердцем у пациента, который поступил в больницу.

Для решения задачи мы будем использовать алгоритм градиентного бустинга в виде обычной модели и в виде мультиагентной системы, которую описали выше. Градиентный бустинг – это техника машинного обучения для задач классификации и регрессии, которая строит модель предсказания в форме ансамбля слабых предсказывающих моделей, обычно деревьев решений.

В результате обучения и тестирования моделей были получены схожие результаты – 82,1% точность классификации в качестве обычной модели и 81,9% у мультиагентной системы. Тестирование проводилось 10 раз – показания являются усредненными.




Рис. 5. Гистограмма с результатами эксперимента

Выводы

Как показал выбранный нами эксперимент, мультиагентная система не показывает явных преимуществ перед классическим подходом с точки зрения именно качества распознавания или скорости, но при этом имеет целый *ряд преимуществ*, связанных именно с архитектурными особенностями такого класса разработок:

1. Любой классификатор можно заменить или дополнить новым.
2. Можно контролировать уровень нагрузки на систему с помощью дублирования некоторых ключевых агентов.
3. Возможность «горячей» замены агентов на более продвинутые версии, при этом не внося изменения в логику работы целого приложения.
4. Отсутствие зависимости от определенной технологии за счет предоставления одинаковых интерфейсов взаимодействия и изоляцией агентов в отдельные контейнеры.

Недостатками такого решения можно считать:

1. Сложность первоначального проектирования и продумывания архитектуры агентов и системы в целом.
2. Трудоемкое тестирование и обучение агентов при использовании только локальной машины.
3. Без готовых мультиагентных систем тяжело проводить эксперименты, не обращаясь за помощью к программистам или иным специалистам.

Планируется продолжать работы и эксперименты в этом направлении. Следующим этапом будет развитие подсистемы «Наблюдателя (супервизора)». Предполагается, что он после сбора необходимого количества информации, используя эволюционные алгоритмы, будет создавать своих агентов классификаторов, но корректируя определенные гиперпараметры, оптимизируя их. Таким образом, в мультиагентную систему будет добавлен объект, который самостоятельно корректирует работоспособность системы. Кроме того, предполагается добавить удобный пользовательский интерфейс для изначальной настройки агентов и отслеживания их продуктивности.

Список литературы

1. Рассел С., Норвиг П. Искусственный интеллект: современный подход. 2-е изд. / пер. с англ. Москва: Издательский дом «Вильямс», 2006. 1408 с.
2. Городецкий В.И., Грушинский М.С., Хабалов А.В. Многоагентные системы (обзор) // Новости искусственного интеллекта. 1998. № 2. С. 64–116.
3. Ньюмен С. Создание микросервисов. – Санкт-Петербург: Питер, 2016. – 304 с.
4. Ferber J. Les Systemes multi-agents: vers ` une intelligence collective. I.I.A. Informatique intelligence artificielle. – InterEditions, 1995.
5. Кошур В.Д., Рожков П.И. Мультиагентная система распознавания изображений // XIX Международная научно—техническая конференция «Нейроинформати-

- ка–2017»: сборник научных трудов. В 2-х частях. Ч. 1. Москва: НИЯУ МИФИ, 2017. С. 121–127.
6. Ландсберг С.Е., Хованских А.А. Особенности построения информационных систем с использованием мультиагентных технологий // Вестник воронежского государственного технического университета. 2014. №3-1. С. 37–39.
 7. <https://www.docker.com/>
 8. <https://scikit-learn.org/>
 9. <https://archive.ics.uci.edu/ml/datasets/heart+Disease>

Ю. Ю. НЕКРАСОВА, А. А. СУДАРЕВА

Московский авиационный институт
(национальный исследовательский университет)
an.sudareva@mail.ru

АДАПТИВНЫЙ СЕНСОМОТОРНЫЙ ИНТЕРФЕЙС «МОЗГ-КОМПЬЮТЕР» ДЛЯ УПРАВЛЕНИЯ СРЕДСТВАМИ РЕАБИЛИТАЦИИ

Рассматривается неинвазивный сенсомоторный интерфейс «мозг-компьютер» (ИМК) на основе электроэнцефалограммы (ЭЭГ) для управления средствами реабилитации, такими как экзоскелеты, искусственные конечности и инвалидные коляски. Особенностью устройства является реализация технологии локализации источников электрической активности мозга (beamforming), применение которой позволит спроектировать нейроинтерфейсное устройство с числом и расположением электродов, оптимальным для конкретного пациента.

Ключевые слова: нейроинтерфейс, интерфейс «мозг-компьютер», ЭЭГ, реабилитация, киберфизические системы.

Введение

Во всем мире согласно исследованию Всемирной организации здравоохранения, 785 миллионов человек в возрасте 15 лет и старше имеют инвалидность, причем 110 миллионов страдают тяжелыми формами заболеваний нервной системы, опорно-двигательного аппарата, расстройствами сенсорных функций, вегетативными состояниями [1]. Задачей реабилитации является восстановление физических, психологических и социальных функций и улучшение качества жизни пациентов. Исследования, проведенные в России [2] и за рубежом [3], показали, что интерфейс «мозг-компьютер» позволяет улучшить результаты реабилитационных процессов посредством формирования связей между неповрежденными участками мозга и вспомогательными устройствами, которые способны компенсировать отсутствующие или поврежденные моторные или сенсорные функции [2]. При этом эффект применения ИМК заключается не только в частичном или полном ассистировании движению, но и в способствовании восстановлению поврежденных функций за счет запускаемых при использовании ИМК механизмов нейрональной пластичности [5].

Задачи создания и совершенствования ИМК являются актуальными и практически значимыми. Так, в качестве вспомогательных устройств, управляемых ИМК, могут выступать роботизированные комплексы ассистирования на основе экзоскелетных модулей [4], что, как ожидается, поз-

волит значительно повысить результаты реабилитации пациентов с поврежденными моторными функциями.

Структурная схема и технические требования к ИМК

Структура адаптивного моторного ИМК для управления современными техническими средствами реабилитации может быть представлена следующими модулями (рис. 1).



Рис. 1. Структурная схема адаптивного моторного ИМК

Блок приема сигналов (БПС) осуществляет запись, усиление, аналого-цифровое преобразование, а также хранение сигналов ЭЭГ совместно со специализированными файлами параметров записи и меток событий. БПС также осуществляет контроль над качеством контакта электродов с кожей головы и качеством получаемого сигнала. При высоком уровне шумов БПС реализует аппаратную фильтрацию нижних частот. Блок обработки сигналов (БОС) включает в себя программные блоки, реализующие цифровую обработку сигналов (ЦОС) и классификацию полученных сигналов. Блок локализации источников (БЛИ) позволяет решать обратную задачу ЭЭГ и определять местонахождение источников нейрональной активности. По данным, поступающим из БЛИ, проводится адаптивное ИМК. Так, в результате нахождения локализации источников возможно сокращение числа электродов и корректирование их местоположения, необходимое для работы моторного ИМК для каждого конкретного пациента, что делает возможным повышение точности работы и удобства использования ИМК, а также снижение его массогабаритных показателей.

После прохождения описанных блоков формируется управляющий сигнал, поступающий на техническое средство реабилитации. Если возможно и целесообразно, средство реабилитации лучше снабдить системой отображения информации для формирования сенсорной обратной связи.

Основными требованиями, предъявляемыми к работе ИМК для управления средствами реабилитации, являются [6]:

- Возможность работы как «offline», так и в режиме реального времени.
- Независимость блоков и компонентов. Данное требование предполагает, что каждый из блоков может быть заменен блоком, выполняющим те же функции другим способом, и при этом не возникнет необходимости в замене остальных блоков.
- Масштабируемость. Конструкция ИМК не должна накладывать ограничений на количество каналов приема информации, частоту дискретизации, число параметров системы или маркеров событий.
- Возможность практической реализации в сфере реабилитации людей с нарушениями моторных функций.

Алгоритм адаптирования ИМК

На этапе адаптации ИМК под пациента для реализации программных блоков ИМК, таких как БОС и БЛИ, используется персональный компьютер с подключаемым к нему электроэнцефалографом. Код программных блоков для ПК написан на языке программирования Python, являющимся на сегодняшний день основным языком для реализации алгоритмов машинного обучения и обработки данных. Для обработки данных использовались библиотеки Scikit-learn, NumPy и SciPy, а также специализированная библиотека для обработки и визуализации биоэлектрических потенциалов MNE [7]. С микроконтроллерными устройствами программные блоки, написанные на Python, взаимодействуют посредством COM порта персонального компьютера.

После проведения записи сигналов энцефалографа и файлов, содержащих параметры системы и маркеры событий, полученные сигналы подвергаются процессам фильтрации и удаления артефактов, выделения признаков и классификации в соответствии с поставленной задачей восстановления моторных функций.

Затем, после реализации алгоритмов поиска локализации источников нейронной активности, проводится выбор значащих каналов для конкретного пациента и собирается адаптированный ИМК с оптимальным числом каналов, подобранными параметрами фильтров и уже обученным классификатором в составе БОС, на основе специально разработанной носимой платформы высокого разрешения. Для программирования платформы используется язык C, метод низковольтного шлейфного программирования микроконтроллеров по стандарту IEEE Std 1149.1 с возможностью отладки (JTAG (Joint Test Action Group)/ SWD (serial wire debugging).

Адаптирование ИМК

А) Монтаж электродов и проведение эксперимента. Для проведения первоначального исследования с целью адаптации ИМК под конкретного пациента электроды располагаются по одной из стандартизованных схем монтажа в соответствии с поставленной задачей (рис. 2). По возможности на этом этапе следует использовать максимально возможное и целесообразное количество электродов.




Рис. 2. Визуализация положения электродов по международной системе 10–20 в программе-обработке

Испытуемому предлагается одновременно с появлением на экране компьютера того или иного сигнала совершить реальное и/или воображаемое движение конечностью в течение заданного времени, чередуя их с полным расслаблением. Полученные сигналы записываются в память ПК. Одновременно формируются файлы, содержащие маркеры событий и параметры системы. Опыт повторяется 3–5 раз.

Для первоначальной апробации предлагаемых концепций использовалась общедоступная база данных EEG Motor Movement/Imagery Dataset, доступная на сайте <https://physionet.org> [8]. Из числа проведенных экспериментов были выбраны три опыта, в которых испытуемый одновременно с появлением в соответствующем месте экрана зрительного стимулятора воображал сжатие обоих кулаков (метка T1), а затем пальцев обеих ног (метка T2), чередуя периоды воображения движения с расслаблением (метка T0).

На рис. 3 представлен двадцатисекундный фрагмент записи ЭЭГ для 10 каналов совместно с маркерами событий.




Рис. 3. Фрагмент записи ЭЭГ

Б) Сегментация сигналов. Процесс выделения временных периодов (эпох), соответствующих маркерам событий, носит название сегментации сигналов. На этом этапе программа-обработчик разбивает сигналы на эпохи, соответствующие отобранному оператором событиям, подсчитывает их количество, при необходимости усредняет сигналы по эпохам для более явного выделения признаков. Для рассматриваемой базы данных выделим эпохи, соответствующие движению рук и ног, усредним их и рассчитаем вызванные потенциалы (рис. 4).




Рис. 4. Усреднение по эпохам, соответствующим движению рук (а) и ног (б)

В) Фильтрация и коррекция артефактов. На этапе программной фильтрации и коррекции артефактов сигнал должен быть отфильтрован в желаемом диапазоне частот, физические и физиологические артефакты удалены. Разработанное ПО позволяет маркировать каналы, качество сигналов с которых неудовлетворительно, и изымать их из рассмотрения. Также возможно ручное маркирование сегментов записи, содержащих излишние шумы или артефакты. Маркированные сегменты в дальнейшем также удаляются из матрицы сигналов.

Для удаления физиологических артефактов используется метод главных компонент, который предполагает нахождение такого ортогонального преобразования исходного сигнала в новую систему координат, для кото-

рого выполняются следующие условия:

- выборочная дисперсия данных вдоль первой координаты максимальна;
- выборочная дисперсия данных вдоль k -й координаты максимальна при условии ортогональности первым $(k - 1)$ координатам.

В результате коэффициент ковариации между проекциями исходного набора данных на различные координатные оси становится равным нулю.

В векторной форме проекция многоканального ЭЭГ сигнала на главные компоненты может быть записана как

$$Y = AX \quad (1)$$

где A – матрица нагрузок; Y – некоррелированный многомерный временной ряд, представляющий собой проекцию исходного сигнала на K главных компонент. При решении задачи удаления артефактов из сигнала ЭЭГ количество компонент K выбирается равным числу каналов.

В рассматриваемой базе данных число артефактов минимально, поэтому работа метода проиллюстрирована выделением главных компонент сигнала, соответствующего воображению движений пальцами ног (рис. 6).




Рис. 6. Главные компоненты эпохи сигнала, соответствующей движению ног

Г) Классификация. На этом этапе необходимо выбрать и реализовать подходящий алгоритм машинного обучения для задачи классификации. Динамические данные, поступающие на вход БОС, следует преобразовать в вектор статических признаков, характеризующих эти данные. Среди множества алгоритмов машинного обучения, применяемых к задачам подобного рода [9], был выбран классификатор на основе алгоритма линейного дискриминантного анализа (ЛДА), представляющего собой обобщение линейного дискриминанта Фишера (англ. Fisher's linear discriminant). Метод используется для поиска линейной комбинации признаков, которая описывает или разделяет два (в общем случае более) класса или события.

Подготовка данных осуществлялась с использованием общего про-

пространственного фильтра (англ. Common Spatial Pattern Filter, CSP), реализующего метод декомпозиции сигналов, основанный на обучении по прецедентам. А именно, каждая из записей многоканальной ЭЭГ полагается относящейся к одному из двух классов с метками 1 и 2. Исходный сигнал X разлагается на такие составляющие, для которых выполняются следующие условия [10]:

- первые k компонент разложения имеют максимальную дисперсию, если X принадлежит к классу с меткой «1», и минимальную дисперсию, если X принадлежит классу с меткой «2»;
- последние k компонент разложения имеют максимальную дисперсию, если X принадлежит к классу с меткой «2», и минимальную дисперсию, если X принадлежит классу с меткой «1».

В результате формируется матрица декомпозиции сигнала.

В аналитической форме общий пространственный фильтр может быть представлен как

$$X_{CSP} = W^T X,$$

где X_{CSP} – компоненты разложения сигнала X ; W – матрица декомпозиции.

В результате применения метода максимальные значения дисперсии для сигнала X_{CSP} будут наблюдаться в первых n каналах, поэтому остальные каналы можно не рассматривать. Для решения задач классификации ЭЭГ принято использовать значение $n = 3$ [11].

Из рис. 7, представляющего результаты применения общего пространственного фильтра, видно, что признаки линейно разделимы. Таким образом, линейный классификатор является оптимальным с точки зрения точности и машинного времени. Кроме того, используемый метод не требует большого числа обучающих выборок для получения достоверного результата [12].




Рис. 7. Результат применения общего пространственного фильтра к рассматриваемой записи ЭЭГ

Для оценки возможностей выбранной модели и настройки ее параметров использовалась кросс-валидация на основе метода Монте-Карло. Правильность работы алгоритма на тестовых данных составила 91%.

Д) Определение локализации источников. Известно, что ЭЭГ, сни-

маемая со скальпа, представляет собой суперпозицию потенциалов от одного или нескольких источников, находящихся во внутренних областях мозга человека. Среди наиболее точных методов локализации источников, т.е. решения обратной задачи ЭЭГ, наибольшее распространение получили методы MNE, beamforming, dSPD и sLORETA. Однако следует отметить, что точная локализация источников мозговой активности является сложной проблемой, требующей зачастую большого объема дополнительных исследований, таких как КТ и МРТ головного мозга, МЭГ и др. Кроме того, полученные результаты сложно интерпретировать, поскольку не всегда ясно, какое количество эквивалентных дипольных источников следует принять в качестве адекватной модели.

Более простым путем поиска локализаций источников нейрональной активности является применение анализа независимых компонент с методом эквивалентных токовых диполей. Суть метода заключается в том, что исходный сигнал разлагается на M максимально независимых компонент, число которых равно числу электродов. Для большей точности метода анализ независимых компонент производится тремя различными методами: FastICA, infomax и extended infomax. Компоненты, степень различия которых от метода к методу превышает заданный порог, отбрасываются. Компоненты, выделяющиеся во всех трех методах, затем представляются в виде эквивалентных токовых диполей [13].

Первые десять компонент сигнала, составленного из эпох, соответствующих движению ногами, представлены на рис. 8. Компоненты, степень дисперсии которых приемлема для дальнейшего анализа, отбираются визуально (подсвечены желтым), хотя в дальнейшем планируется поиск оптимального алгоритма выбора значимых компонент.




Рис.8. Независимые компоненты, отобранные для дальнейшего анализа

В качестве модели головы используется модель, полученная методом граничных элементов (англ. Boundary element model, BEM). Этот метод позволяет решить прямую задачу ЭЭГ в предположении постоянной про-

водимости внутри каждого из трех выделяемых слоев, к которым относятся кожа, череп и кора головного мозга. Выбранная модель в целом точнее сферической, несмотря на то, что она является численной, тогда как сферическая модель – аналитическая.

Для выбранной компоненты, отмеченной на рис. 8 и представляющей симметричную активность правой и левой долей, выбрана модель, состоящая из двух дипольных источников, локализация и направление которых показаны на рис. 9.




Рис. 9. Локализация токового диполя для одной из независимых компонент

На этом адаптирование ИМК заканчивается. На основе проведенных расчетов производится выбор необходимого числа электродов, параметры рассчитанных моделей переносятся на носимую платформу на основе микроконтроллера.

Результаты

Для проверки правильности проведенных расчетов, а также качества работы ИМК была промоделирована непрерывная подача сигналов рассматриваемой базы данных в БОС с помощью специализированного симулятора потока реальных данных MNE Real-time server.

К СОМ порту ПК подключалось микроконтроллерное устройство на основе МК Atmega 328P-PU, снабженное средствами индикации (рис. 10).

Линейный классификатор, работая в режиме онлайн, различал эпохи, соответствующие движению руками и ногами, и передавал ту или иную команду в СОМ порт ПК. Команда считывалась микроконтроллерным устройством, которое в соответствии с программой управляло средствами индикации.




Рис. 10. Микроконтроллерное устройство для тестирования работы БОС ИМК

По результатам эксперимента был сделан вывод о том, что точность работы классификатора является удовлетворительной для задач проектирования ИМК для управления современными техническими средствами реабилитации.

Список литературы

1. <https://apps.who.int/iris/bitstream/handle/10665/70670/?sequence=7>
2. Бирюкова Е. В., Бушкова Ю. В. [и др.]. Объективная оценка состояния двигательной функции до и после реабилитации по технологии ИМК+экзоскелет: биомеханический анализ тестов шкалы Fugl-Meyer // XI международный конгресс «Нейрореабилитация-2019», Москва, 14–15 марта 2019 г.
3. Lebedev M.A., Nicolelis M.A. Brain-machine interfaces: past, present and future // Trends Neurosci. 2006, Sep; 29 (9): 536–46. Epub 2006 Jul 21.
4. Дудоров Е.А., Богданов А.А., Пермяков А.Ф. Роботизированные комплексы интеллектуального ассистирования специального и медицинского назначения // Наука и инновации в медицине. № 3, 2016.
5. Carmena, J.M., [et al.]. Learning to control a brain-machine interface for reaching and grasping by primates // PLoS Biol. 2003. 1(2): E42.

6. Schalk G., McFarland D. J., Hinterberger T., Birbaumer N. and Wolpaw J. R. BCI2000: a general-purpose brain-computer interface (BCI) system // IEEE Transactions on Biomedical Engineering. Vol. 51, no. 6. P. 1034–1043, June 2004.
7. <https://martinos.org/mne/dev/index.html>
8. <https://physionet.org/pn4/eegmmidb/>
9. Сотников П.И. Обзор методов обработки сигнала электроэнцефалограммы в интерфейсах мозг-компьютер // Инженерный вестник. № 10, октябрь 2014.
10. Blankertz B., Tomioka R., and Lemm S., Optimizing Spatial Filters for Robust EEG Single-Trial Analysis // IEEE SIGNAL PROCESSING MAGAZINE, 2008. Vol. XX, P. 581-607.
11. Zhang D., Wang Y., and Gao X., An Algorithm for Idle-State Detection in Motor-ImageryBased Brain-Computer Interface // Computational Intelligence and Neuroscience. 2007. Vol. 2007. 9 p.
12. Xu B.G., Song A.G., Pattern recognition of motor imagery EEG using wavelet transform // J. Biomedical Science and Engineering. 2008. Vol. 1. P. 64–67.
13. <https://sccn.ucsd.edu/~klaus/pubs/Wentrup%20etal%202007%20ProcIEEE.pdf>

Ю. А. СКОБЦОВ¹, О. В. ЧЕНГАРЬ²

¹Санкт-Петербургский государственный университет аэрокосмического приборостроения

²Севастопольский государственный университет
ya_skobtsov@list.ru, OVChengar@sevsu.ru

СИНТЕЗ ПРОИЗВОДСТВЕННЫХ РАСПИСАНИЙ НА ОСНОВЕ МНОГОКРИТЕРИАЛЬНОГО МУРАВЬИНОГО АЛГОРИТМА

Предложен метод многокритериальной оптимизации с адаптивными весами, где в процессе поиска решения корректируются веса целевой функции. Для оптимизации работы автоматизированного технологического комплекса обработки совместно с модифицированным муравьиным алгоритмом используется объектная имитационная модель, которая позволяет рассчитывать значения фитнес-функции и оценивать потенциальные решения. Определены правила перехода и расчета концентрации синтетического феромона для направленных муравьиных алгоритмов. Проведены экспериментальные исследования оптимизации производственного расписания для двух и трех критериев на примере автоматизированного технологического комплекса обработки.

Ключевые слова: многокритериальная оптимизация, муравьиные алгоритмы, производственные расписания.

Введение

При решении реальных практических задач, как правило, необходимо проводить оптимизацию по нескольким критериям, что имеет свои особенности и требует использования специальных методов, которые значительно отличаются от стандартной техники, ориентированной на оптимизацию одной функции. Поэтому при многоцелевой оптимизации поиск проводится не по одному решению, а по набору потенциальных решений, образующих фронт Парето. Специфика организации современного производства заключается в использовании гибких производственных систем (ГПС), позволяющих переходить с одного изделия на другое с минимальными затратами времени и труда. Использование таких систем предполагает сложный мульти-технологический инструментарий – гибкие производственные модули (ГПМ) [1, 2]. Они характеризуются сложностью управления и процесса планирования, особенно в мелкосерийных и средних сериях многопрофильного производства. Поэтому проблема оптимизации производственных расписаний с целью повышения производитель-

ности работ ГПС является актуальной и имеет большое практическое значение. В данной работе рассматривается задача многокритериальной оптимизации производственных расписаний с использованием модификации муравьиного алгоритма (МА) [3] с адаптивными весами. Присущие МА свойства способствуют их эффективному использованию при решении задач многокритериальной оптимизации, поскольку МА используют множество потенциальных решений – популяцию и глобальный поиск по нескольким направлениям [3, 4]. Кроме того, МА не накладывает каких-либо требований на тип целевых функций и ограничений. Для оценки качества потенциальных решений в процессе поиска решений на основе МА используются объектно-ориентированные модели, которые описывают наиболее важные характеристики систем и позволяют моделировать их функционирование с приемлемой точностью. Данная работа является развитием исследований [1, 2, 5, 6].

Постановка задачи

Задача построения производственного расписания работы ГПС состоит в том, чтобы для производственного участка с определенным технологическим маршрутом составить необходимый порядок обработки деталей с учетом ограничений, которые отражают реальные производственные ситуации за данное время. Модель этого процесса удобно представить в виде направленного графа, построение которого эквивалентно определению чисел t_{ij} – моментов времени запуска процесса для технологической операции O_{ij} [1, 2]. Множество чисел $\{t_{ij}\}$ ($i = 1, 2, \dots, n$; $j = 1, 2, \dots, m_i$), которое удовлетворяет сформулированным условиям, называется *графом работы ГПС*, или его *графовой моделью* $G(i)$ [1, 4].

Помимо соответствующего представления в виде графа процесса загрузки технологического оборудования, необходимо выполнить следующую последовательность действий ГПС для адаптации МА для решения поставленной проблемы.

1. Определить метод кодирования потенциальных решений.
2. Сформулировать правила коррекции концентрации искусственного феромона, которые учитывают качество построенных потенциальных решений.
3. Разработать эвристики для определения выбора дуги при построении траектории на графе.
4. Определить эвристическое поведение муравья при выборе следующей дуги в графе в виде вероятности перехода.
5. Определить средства проверки корректности потенциального решения с учетом ограничений проблемы.
6. Проверить адекватность модели.

В [2] исследуется проблема разработки и построения графоаналитической модели в соответствии с выбранным критерием оптимизации

$$G = (V, D, P), \quad (1)$$

где: V – множество вершин, каждая из которых определяет позицию обрабатываемых компонентов; D – множество дуг, представляющих переход от одного шага процесса к другому; P – матрица правил переходов, где каждой дуге $(i, j) \in D$ приписан вес P_{ij} . На основе разработанной графоаналитической модели предложен алгоритм эволюции популяций муравьев для моделирования производственного процесса в ГПС [1]. Этот алгоритм учитывает различные внешние воздействия, такие как нарушения ГПМ, плановые работы по техническому обслуживанию, ввод в эксплуатацию оборудования, задержки в подаче материалов и т. д., а также наличие ГПС-оборудования и складского оборудования. Поэтому при составлении расписания имитируются начало и конец каждой технологической операции выбранного типа для технологического оборудования.

Направленный муравьиный алгоритм

На основе предложенной графоаналитической модели процесса загрузки технологического оборудования ГПС разработана новая модификация МА – «направленный муравьиный алгоритм» [1]. Эта модификация отличается от своих аналогов следующими особенностями:

1) Предложенный метод расчета вероятностей перехода искусственного муравья в узле графоаналитической модели основан на анализе текущей ситуации производства.

2) Однозначно определяется необходимое количество искусственных муравьев в каждой популяции, в том числе «элитных» особей, что зависит от ремонта и готовности к эксплуатации технологического оборудования в производственной зоне.

3) Определяется доступный набор узлов для искусственных муравьев для посещения следующих узлов, который содержит узлы верхнего списка – кандидатов на их посещение, а для всех муравьев, кроме «элитных» муравьев, список запрещенных переходов (табу) генерируется.

4) Предложено изменить глобальное правило коррекции концентрации феромона на дугах графов, принимая во внимание не «лучшие», как это принято считать, а «наихудшие» пути в популяции искусственных муравьев с целью улучшения ее в следующей итерации.

5) Эвристическая информация основана на «прямо пропорциональном» правиле для перехода между узлами.

Рассмотрим основные особенности предлагаемого способа.

1. Как упоминалось ранее, для искусственного муравья выбор следующего узла не является случайным и производится с учетом текущей производственной ситуации и динамически изменяющейся среды и эвристической информации, собранной на данный момент.

Вероятность перехода k -го муравья в узел O_{ij} определяется соотношением (2):

$$\begin{cases} P_{ij,k}(t) = \frac{[\tau_{ij}(t)]^\alpha \cdot [\eta_{ij}(t)]^\beta}{\sum_{k=1}^l [\tau_{ij}]^\alpha [\eta_{ij}(t)]^\beta}, & O_{ij} \in N_{ij}^k, \\ P_{ij,k}(t) = 0, & O_{ij} \notin N_{ij}^k, \end{cases} \quad (2)$$

где α – коэффициент значимости концентрации феромона;
 β – коэффициент важности для эвристической информации;
 τ_{ij} – концентрация феромона на дуге графика;
 η_{ij} – эвристическая информация;
 N_{ij}^k – список вершин O_{ij} , доступных для k -го муравья.

2. Предпочтительный выбор следующего узла для графоаналитической модели, основанный на «прямо пропорциональном» правиле перехода между узлами, в отличие от некоторых известных модификаций алгоритма муравья [3, 4], когда муравей определяет следующий узел, сначала наугад, а затем пропорционально количеству феромона.

«Прямо пропорциональное» правило перехода, основанное на эвристической информации, которая определяется как отношение (3) времени выполнения T_{oij} технологических операций к запланированному времени T_{sij} , которое, в свою очередь, корректируется после каждого шага процесса детализации партии, согласно формуле (4):

$$\eta_{ij} = \frac{T_{oij}}{T_{s_i}}, \quad (3)$$

где T_{oij} – время выполнения технологической операции детализации партии O_{ij} i -типа;

T_{s_i} – срок изготовления деталей партии i -типа

$$T_{s_i} = T_{s_i} - T_{os_{ij}}. \quad (4)$$

Приведенная формула эвристического расчета (3) позволяет улучшить характеристики МА, так как в процессе поиска муравей выбирает не тот узел, который свободен после следующей производственной операции, а узел, где детали партии скоро завершатся обработка [5].

3. На каждой итерации «направленного» МА все искусственные муравьи постепенно строят пути от начального до конечного узла графоаналитической модели. При этом на каждом узле искусственный муравей должен выбрать следующий узел пути графа. Если k -й муравей находится в узле O_{ij} , он выбирает следующий узел на основе вероятностей перехода (2).

Для расчета концентрации феромона при переходе к следующему узлу в графе муравья используются «глобальные» правила, способствующие направленному поиску. Эти правила заставляют муравьев двигаться к

найденным «худшим» решениям с целью «улучшения». Эта стратегия благоприятствует использованию пространства поиска и используется после построения решения, то есть после генерации пути всеми муравьями. Более того, концентрация феромона позволяет изменять только самому «худшему» (в глобальном смысле) муравью, чтобы построить неоптимальный путь $x(t)$. Таким образом, для каждого дуги графа концентрация феромона определяется по следующему правилу (5–6):

$$\tau_{ij}(t+1) = \tau_{ij}(t) + \Delta\tau_{ij}(t), \quad (5)$$

где

$$\Delta\tau_{ij}(t) = \sum_{k=1}^{n_k} \Delta\tau_{ij}^k(t). \quad (6)$$

Концентрация феромона для каждого искусственного муравья вычисляется в зависимости от желаемого критерия оптимальности и рассчитывается по одному из следующих правил (7 – 9):

- для максимизации среднего коэффициента загрузки оборудования:

$$\Delta\tau_{ij}^k(t) = \frac{1}{\sum_{i,j} Tn\rho_{ij}^k} \quad (7)$$

где – время простоя k -го оборудования до проведения технологического этапа O_{ij} .

- для задачи минимизации времени переключения оборудования:

$$\Delta\tau_{ij}^k(t) = \frac{1}{\sum_{i,j} Tn_{ij}^k}, \quad (8)$$

где – время установки для выполнения операции изготовления ГПС O_{ij}

- для задачи минимизации времени цикла изготовления деталей детали:

$$\Delta\tau_{ij}^k(t) = \frac{1}{\sum_{i,j} Tn\rho_{ij}^k + To_{ij}^k}. \quad (9)$$

В (7–9) отложение феромона обратно пропорционально качеству полного пути к построенным муравьям аркам. Тогда эта глобальная информация используется для коррекции концентрации феромона. Кроме этого, выполнены некоторые улучшения МА по сравнению с [5, 6].

Многокритериальная оптимизация производственного расписания

Метод взвешенных функций является одним из наиболее популярных и естественным развитием классических методов оптимизации для многокритериальной оптимизации, где новая «общая» целевая функция строится из отдельных целевых функций в форме взвешенной суммы [5]:

$$F(x) = \sum_{i=1}^k w_i f_i(x). \quad (10)$$

Здесь каждой целевой функции $f_i(x)$ присвоен вес w_i , и задача сводится к скалярному случаю. В то же время разные веса дают различные решения

в смысле Парето. При параллельном поиске нескольких решений веса не фиксированы, что позволяет «направленному» алгоритму муравья расширять фронт поиска во всех направлениях [5]. В предлагаемом алгоритме, согласно определенному критерию оптимизации, набор решений формируется на основе «направленного» алгоритма муравья на каждой итерации. Далее для исследуемых решений определяются максимальные и минимальные экстремальные точки в пространстве заданных критериев. В результате мы получаем гиперплоскость, которая определяется двумя крайними точками и содержит все текущие решения. Эти две крайние точки обновляются на каждой итерации. В этом случае адаптивный вес k -й цели определяется соотношением [5].

$$w_k = \frac{1}{z_k^{\max} - z_k^{\min}}, \quad k = 1, 2, \dots, q. \quad (11)$$

Для каждой цели на основе выбранных критериев устанавливаются средневзвешенные коэффициенты значимости (12), которые нормируются внутри группы:

$$w_k^{\text{норм.}} = \frac{w_k}{\sum_{i=1}^q w_i}, \quad k = 1, 2, \dots, q. \quad (12)$$

Затем на каждой итерации взвешенная целевая функция определяется в соответствии со следующим выражением (13).

$$z(x) = \sum_{k=1}^q w_k^{\text{норм.}} (f_k(x) - z_k^{\min}). \quad (13)$$

В начале алгоритма предполагается, что все значения $Z^{\min}$ и $Z^{\max}$ обнуляются. Поскольку крайние точки обновляются на каждой итерации, веса обновляются соответственно. Все исследуемые решения Парето лежат в пространстве образов z , и в процессе поиска решений с каждой популяцией муравьев гиперплоскость последовательно приближается к положительной (или отрицательной) идеальной точке. В результате этот метод позволяет корректировать веса целевой функции и направляет поиск решений в правильном направлении. Следует отметить, что каждый из критериев оптимальности может иметь свою собственную точность решения, которая достигается с помощью различных чисел итерации. Поэтому для определения числа итераций n_i были проведены экспериментальные исследования всех однокритериальных задач и определено количество итераций, при которых будет достигнута точность, соответствующая технологическим условиям. Таким образом, метод многокритериальной оптимизации, описанный выше, позволяет охватить все пространство решений для каждой популяции муравьев и выбрать из них способы, которые являются оптимальными в смысле Парето.

Экспериментальные исследования

В ходе эксперимента с помощью объектной модели ГПС многокритериальные задачи решены с использованием «направленного» алгоритма муравья с адаптивными весами. Проведен анализ результатов в сравнении с решениями, полученными при решении однокритериальной задачи. Рассмотрим следующие варианты выбора критериев оптимальности:

I. Максимизация среднего коэффициента загрузки технологического оборудования.

II. Минимизация нарушения сроков изготовления заказа при минимальной продолжительности цикла изготовления деталей.

III. Минимизация нарушения сроков изготовления заказа при минимизации времени на замену оборудования.

IV. Минимизация нарушения сроков изготовления заказа при минимальной продолжительности изготовления деталей и времени сменного оборудования.

При анализе полученных решений выявлена зависимость среднего коэффициента загрузки технологического оборудования (K_{srs}) и времени нарушения сроков выполнения заказа (T_{cp}) в зависимости от количества популяций муравьев n_t для каждого из вариантов выбора критерия оптимальности считались. Эти параметры не были выбраны случайным образом, потому что максимизация KSSR также включает в себя минимизацию производственного цикла и настроек оборудования одновременно. Результаты представлены на рис. 1 и 2 соответственно.

Анализ результатов показывает, что предложенный многокритериальный «направленный» МА с адаптивными весами требует больше итераций, чем аналогичный алгоритм для задачи с одним критерием. Более того, с увеличением числа критериев увеличивается число популяций муравьев для нахождения оптимального по Парето решения.

Итак, по ключевым параметрам эффективности наблюдается следующая тенденция: для задачи с одним критерием (вариант I) число итераций, необходимое для достижения неоптимального решения, $n_t = 110$, для задач с двумя критериями (варианты I и II) $n_t = 170$, а для трехкритериальной задачи (вариант IV) $n_t = 230$. Однако, если «направленному» МА предоставить заданное количество ресурсов n_t , он неизменно показывает свою эффективность и позволяет получить хорошие решения, близкие к фронту Парето.




Рис. 1. Зависимость среднего коэффициента загрузки оборудования от количества итераций для различных вариантов критериев оптимальности




Рис. 2. Зависимость времени нарушения сроков производства от числа итераций для различных вариантов выбора критериев оптимальности

Выводы

Предложен метод многокритериальной оптимизации производственных расписаний ГПС на основе модификации муравьиного алгоритма и метода взвешенной функции, который отличается от известных по следующим аспектам.

1. Сформулированы правила выбора следующего узла графоаналитиче-

ской модели, основанные на «прямо пропорциональном» правиле перехода между узлами.

2. Предложены «глобальные правила» для расчета концентрации феромона при переходе искусственного муравья к следующему узлу на графе, что облегчает выбор направления поиска.

3. Объектно-ориентированная имитационная модель ГПС используется для оценки качества потенциальных решений.

4. Компьютерные эксперименты показывают, что многокритериальная оптимизация на основе «направленного» алгоритма муравья с адаптивными весами позволяет получить более адекватные результаты.

Список литературы

1. Skobtsov Yu., Chengar O., Skobtsov V., Pavlov A. Synthesis production schedules based on ant colony optimization method // Proceedings of the 6th Computer Science online Conference 2017 (CSOC2017), in Advances in Intelligent Systems and Computing (eds. Janusz Kacprzyk et al.). Springer International Publishing Switzerland, 2017. –Vol. 1 (573), 2017. P. 456-465.
2. Skobtsov Y, Sekirin A., Zemlyanskaya S., Chengar O., Skobtsov V., Potryasaev S. Application of object-oriented simulation in evolutionary algorithms // Automation Control Theory Perspectives in Intelligent Systems, Advances in Intelligent Systems and Computing vol. 466. – Switzerland: Springer International Publishing, 2016. P. 453-462.
3. Dorigo M. Swarm Intelligence, Ant Algorithms and Ant Colony Optimization. Reader for CEU Summer University Course “Complex System”/ Dorigo M. Budapest, Central European University, 2001. P. 1–3.
4. Родзин С.И., Скобцов Ю.А., Эль-Хатиб С.А. Биоэвристики: теория, алгоритмы и приложения : монография. – Чебоксары: ИД «Среда», 2019. – 224 с. – ISBN 978-5-6042304-6-6. doi:10.31483/r-22141.
5. Ю.А. Скобцов, О.В. Ченгарь. Парето-оптимизация производственного расписания на основе метода муравьиных колоний // Онтология проектирования. 2018. Т. 8, № 3(29). P. 469-479.
6. Ю.А. Скобцов, О.В. Ченгарь. Экспериментальное исследование «направленного» муравьиного алгоритма оптимизации производственного расписания // Труды XIX международной научно-технической конференции. «Нейроинформатика-2017». С. 152-161.

Е. Е. ВИТЯЕВ

Институт математики им. С.Л. Соболева, Новосибирск
vityaev@math.nsc.ru

СОЗНАНИЕ КАК КОМПЛЕКСНОЕ ОТРАЖЕНИЕ ПРИЧИННО-СЛЕДСТВЕННЫХ СВЯЗЕЙ ВНЕШНЕГО МИРА*

В предыдущих работах была решена проблема статистической двусмысленности и определены максимально специфические причинно-следственные связи, вывод по которым непротиворечив. В данной работе аргументируется следующая гипотеза: мозг делает все возможные выводы по воспринимаемым причинно-следственным связям, создавая непротиворечивую модель воспринимаемого мира, проявляющуюся как сознание. Показано, что предложенная модель сознания является вариантом теории сознания Г. Топони, основанной на интегрированной информации.

Ключевые слова: категоризация, естественная классификация, естественные понятия, интегрированная информация.

Введение

Г. Топони [1–3] определяет сознание как первичное понятие, которое обладает следующими феноменологическими свойствами: composition, information, integration, exclusion. Для более точного определения этих свойств Г. Топони [1] вводит понятие интегрированной информации: «интегрированная информация, характеризующая редукцию неопределенности, – это информация, генерируемая системой, приходящей в некоторое состояние через причинное взаимодействие между ее частями, которая превосходит информацию, генерируемую независимо ее частями самими по себе». В терминах интегрированной информации феноменологические свойства формулируются следующим образом.

- 1) composition – elementary mechanisms (causal interactions) can be combined into higher order ones;
- 2) information – only mechanisms that specify ‘differences that make a difference’ within a system count;
- 3) integration – only information irreducible to non-interdependent components counts;
- 4) exclusion – only maxima of integrated information count.

* Работа выполнена при частичной поддержке РФФИ, грант № 19-01-00331 а.

Г. Топони рассматривает эти свойства как внутренние свойства системы. Интегрированная информация у Г. Топони рассматривается как система циклических причинных связей. Однако он не определяет, что же отражает интегрированная информация помимо феноменологических свойств.

В данной работе нами выдвигается гипотеза о том, что мозг с помощью интегрированной информации настраивается на восприятие «естественных» объектов внешнего мира. Мы рассматриваем эти свойства не как внутренние свойства системы, а как способность системы отражать комплексы причинных связей объектов внешнего мира, а сознание – как способность комплексного иерархического отражения «естественной» классификации внешнего мира.




Рис. 1. Отражение мозгом причинных связей между свойствами объектов

Рассмотрим процесс отражения причинных связей (рис. 1). Он включает:

- 1) объекты внешнего мира (машина, лодка, причал), относящиеся к некоторым «естественным» классам;
- 2) процесс отражения мозгом свойств объектов и связывающих их причинных связей;
- 3) объединение возбужденных нейронов мозга в системы, обозначенные овалами.

В теории Г. Топони рассмотрен только третий пункт процесса отражения. Мы покажем, что интегрированная информация может рассматриваться не только как формализация феноменологических свойств, но и как комплексное иерархическое отражение «естественной» классификации внешнего мира, при определенной ее модификации.

Причинные связи и «естественная» классификация

Причинность является следствием физического детерминизма: «для любой изолированной физической системы некоторое ее состояние определяет все последующие состояния» [4]. Рассмотрим автомобильную аварию [4]. В чем её причина? Это может быть состояние дорожного покрытия

тия, его влажность, положение солнца относительно водителя, безрассудное вождение, психологическое состояние водителя, неисправность тормозов и т.д. Очевидно, что в этом случае нет определенной причины.

В философии науки причинность сводится к предсказанию и объяснению. «Причинно-следственная связь означает предсказуемость... в том случае, если известна вся предыдущая ситуация, событие может быть предсказано..., если даны все факты и законы природы, связанные с этим событием» [4]. Понятно, что знать все факты, число которых в случае аварии потенциально бесконечно, и все законы никто не может. Кроме того, человек и животные узнают законы путем обучения (индуктивного вывода). Поэтому причинность сводится к предсказанию с помощью индуктивно-статистического вывода, когда предсказание логически выводится из фактов и статистических законов с некоторой вероятностной оценкой.

Причинно-следственные связи, обнаруженные на реальных данных или в результате обучения, сталкиваются с проблемой статистической двусмысленности – из них могут быть выведены противоречивые предсказания [5–6]. Чтобы избежать этой двусмысленности, Гемпель ввел требование максимальной специфичности [5–6], состоящее в том, чтобы статистические законы включали максимум информации, связанные с прогнозируемым свойством. Следуя Гемпелю, мы определили максимально специфические правила, для которых удалось доказать, что индуктивно-статистических вывод, использующий их, не приводит к противоречиям [7–8]. Для обнаружения таких максимально специфических правил был разработан специальный семантический вероятностный вывод, который можно рассматривать как метод обнаружения максимально специфических причинно-следственных связей. На основе этого вывода разработана формальная модель нейрона, удовлетворяющая правилу Хебба, в которой этот вывод обнаруживает максимально специфические причинно-следственные связи [9]. Причинно-следственные связи могут заикливаться, создавая неподвижные точки циклически взаимно предсказывающихся атрибутов. Эти неподвижные точки имеют особый смысл и отражают «естественную» классификацию объектов внешнего мира. В сознании они проявляются как перцептивные циклы. Хороший пример таких циклов приводит У. Найсер: "Мы записали на видеомагнитофон две "игры" (например, футбол и хоккей – Е.В.), а затем с помощью зеркала осуществили полное визуальное наложение двух передач – как если бы на телевизионном экране одновременно демонстрировались два канала... Испытуемых просили наблюдать за одной игрой и игнорировать другую, нажимая на ключ при каждом целевом событии (например, при каждом ударе по мячу, шайбе – Е.В.)... При темпе 40 целевых событий в минуту было одинаково легко следить за игрой независимо от того, демонстрировалась она вместе с другой или отдельно. Количество ошибок составляло

примерно 3%... Естественность этой задачи и отсутствие интерференции со стороны второго эпизода просто удивительны. Испытуемый *не видит* иррелевантную игру... Циклическая модель восприятия позволяет легко объяснить эти результаты" [10].

Строение объектов внешнего мира впервые было проанализировано в области «естественной» классификации. Было замечено, что «естественные» классы животных или растений отличаются потенциально бесконечным множеством свойств [11]. Естествоиспытатели, строившие «естественные» классификации, отмечали, что построение «естественной» классификации заключается в «индикации» – от бесконечно большого числа признаков нужно перейти к ограниченному их количеству, которое заменило бы все остальные признаки [12]. Это означает, что в «естественных» классах признаки сильно коррелированы, например, если есть 128 классов и атрибуты двоичные, то независимыми «индикаторными» атрибутами среди них будут около 7 атрибутов, т.к. $2^7 = 128$, а другие атрибуты могут быть предсказаны по значениям этих 7 атрибутов. Мы можем выбирать различные 7–15 атрибутов в качестве «индикаторных» и тогда другие атрибуты, которых потенциально бесконечное количество, могут быть предсказаны на основе этих выбранных атрибутов. Поэтому существует огромное множество причинно-следственных связей между атрибутами «естественных» классов.

Мы формализуем «естественную» классификацию путем обобщения анализа формальных понятий [13]. Формальные понятия могут быть определены как неподвижные точки детерминированных правил (не имеющих исключений) [13]. Мы обобщаем формальные понятия на вероятностный случай, заменяя детерминированные правила вероятностными максимально специфическими правилами и определяя вероятностные формальные понятия как неподвижные точки этих максимально специфических правил [14–15]. Можно показать [16], что вероятностные формальные понятия формализуют «естественную» классификацию, если их применить к некоторой выборке из генеральной совокупности. При этом полученная «естественная» классификация будет удовлетворять всем требованиям, которые естествоиспытатели предъявляли к «естественным» классификациям [16].

Алгоритм «естественной» классификации основан на определенном критерии максимальной согласованности причинных связей по взаимному предсказанию, который близок по смыслу интегрированной информации и тоже «измеряет» «интегрированность» причинных связей. Подробнее он рассмотрен в последнем разделе.

«Естественная» классификация и «естественные» понятия

Высокая корреляция признаков для «естественных» классов была подтверждена и в когнитивной науке. Eleanor Rosch сформулировала прин-

ципы категоризации, одним из которых является следующий: «воспринимаемый мир не является неструктурированным набором свойств, обнаруживаемых с равной вероятностью, напротив, объекты воспринимаемого мира имеют сильно коррелированную структуру» [17–18]. Непосредственно воспринимаемые объекты (basic objects) – информационно богатые связки наблюдаемых и функциональных свойств, которые образуют естественную разрывность, создающую категоризацию. Позже Bob Rehder предложил теорию причинных моделей, в которой отношение объекта к категории основывается уже не на наборе атрибутов, а на близости порождающих причинных механизмов: «объекты классифицируются как члены некоторой категории в той степени, в которой его свойства, вероятно, были сгенерированы причинными законами данной категории» [19]. Таким образом, структура причинно-следственных связей между атрибутами объектов берется за основу категоризации. Поэтому «естественные» объекты воспринимаются не как набор атрибутов, а как «резонирующая» (с точки зрения клеточных ансамблей нейронов) система причинно-следственных связей. В то же время «резонанс» возникает тогда и только тогда, когда эти причинно-следственные связи отражают некоторую целостность некоторого «естественного» класса, в котором потенциально бесконечное количество атрибутов взаимно предсказывают друг друга. Для формализации причинных моделей Bob Rehder предложил использовать причинно-следственные графические модели [20]. Однако эти модели основаны на «развертывании» байесовских сетей, которые не допускают циклов и не могут формализовать циклические причинно-следственные связи. Разработанные нами вероятностные формальные понятия непосредственно формализуют циклические причинно-следственные связи [14–16].

Нейрон передает свое возбуждение другим нейронам через множество возбуждающих и тормозных синапсов. Ингибирующие синапсы могут тормозить нейроны. Это важно для «подавления» восприятия альтернативных образов, атрибутов и свойств. В рамках нашей формальной модели это достигается путем обнаружения «тормозных» причинно-следственных связей, которые предсказывают отсутствие атрибута/свойства объекта (воспринимаемый объект не должен иметь соответствующий атрибут/свойство). В формальной модели это определяется путем введения отрицаний для предикатов соответствующих атрибутов/свойств. Нами доказано [15–16], что в неподвижных точках, использующих только максимально специфические причинно-следственные связи, не возникает противоречий – не возникает ситуации, когда одновременно предсказывается наличие некоторого атрибута/свойства и его отсутствие.

Следует особо отметить, что «резонанс» взаимных предсказаний вос-

принимаемых свойств объектов (стимулов) осуществляется непрерывно во времени и поэтому предсказанные свойства должны точно совпадать с тем, что воспринятыми. Отсутствие противоречий в предсказаниях также является отсутствием противоречий между предсказанными стимулами и воспринятыми стимулами.

Альтернативный способ измерения интегрированной информации

Если «естественная» классификация описывает объекты внешнего мира, а когнитивные науки – восприятие объектов внешнего мира, то теория интегрированной информации, с нашей точки зрения, анализирует информационные процессы мозга по восприятию «естественной» классификации объектов внешнего мира. В этом случае феноменологические свойства, вводимые G.Топпи, могут быть проинтерпретированы в терминах «естественной» классификации следующим образом:

1) composition – «естественные» классы в виде причинных циклов образуют иерархию «естественных» классов;

2) information – совокупность различий приводит к качественному отличию или, иначе, качественно отличающиеся объекты различны по целой совокупности различных свойств. В нашей формализации циклические причинные связи автоматически формируют паттерны различающихся свойств;

3) integration – значима только система «резонирующих» причинных связей, свидетельствующая об избытке информации и восприятии высоко коррелированной структуры «естественного» объекта);

4) exclusion – только значения признаков, максимально взаимосвязанных причинными связями формируют «образ» или «прототип».

Теоретические результаты о непротиворечивости индуктивно-статистического вывода и непротиворечивости неподвижных точек предполагают, что известна вероятностная мера событий. Однако если мы обнаруживаем причинно-следственные связи на обучающей выборке и предсказываем свойства нового объекта, случайно выбранного из генеральной совокупности, или распознаем новый объект как член некоторого «естественного» класса, то противоречия могут возникать.

В этом случае мы используем определенный критерий максимальной согласованности причинных связей по взаимному предсказанию, основанный на информационной мере, близкой по смыслу к энтропийной мере интегрированной информации [21]. Сравним эти критерии.

Интегрированная информация G. Топпи основывается на эффективной информации ei , генерируемой системой. Она определяется как разница энтропии априорного состояния системы и апостериорного состояния системы, приводящего к некоторому состоянию x_1 через причинные связи [2]:

$$ei(X_0 \rightarrow x_1) := H(p^{\max}(X_0)) - H(p(X_0 \rightarrow x_1)),$$

где $p^{\max}(X_0)$ – распределение на состояниях системы с максимальной энтропией (maxent), $p(X_0 \rightarrow x_1)$ – распределение на состояниях системы, которые приводят к состоянию x_1 через причинные связи, $H(p(-))$ – энтропия распределения p .

Эффективная информация показывает, сколько информации генерируется системой без учета ее интеграции. Для определения интегрированной информации надо знать, сколько информации генерируется системой как целым по отношению к информации, генерируемой независимо ее частями. Для этого определяется некоторое минимальное информационное разбиение P^{MIP} и интегрированная информация приобретает вид [2]:

$$\phi(x_1) = H \left[p(X_0 \rightarrow x_1) \parallel \prod_{M^k \in P^{MIP}} p(M_0^k \rightarrow \mu_1^k) \right].$$

Опираясь на интегрированную информацию, G. Tononi определяет комплексы (которые, с нашей точки зрения, способны улавливать комплексы стимулов объектов «естественных» классов) как систему S с входным состоянием s_1 , $\phi(s_1) > 0$, такую, что S не содержится в некотором большем подмножестве со строго большим значением интегрированной информации ϕ . Это означает, что в комплексе достигается локальный максимум интегрированной информации.

Аналогично, для определения «естественных» классов алгоритм «естественной» классификации использует локальный максимум критерия согласованности причинных связей по взаимному предсказанию свойств объектов. Поскольку, согласно теории, «естественные» классы образуют неподвижную точку взаимных предсказаний признаков класса, то в этой неподвижной точке должен достигаться максимум согласованности причинных связей по предсказанию и одновременно максимум информационной взаимосвязи признаков класса. Поэтому критерий согласованности имеет следующий вид [21]:

$$\text{Krit}(X) = \sum_{R \in S(X)} H(R) - \sum_{R \in F(X)} H(R), \text{ где } H(R) = -\log(1 - \text{prob}(R)),$$

где частная энтропия $H(R)$ учитывает не саму условную вероятность $\text{prob}(R)$ причинной связи R , а ее близость к 1. Множество причинных связей $S(X)$ – это те, которые подтверждаются в неподвижной точке (предсказываемое значение совпадает с существующим в неподвижной точке), и $F(X)$ – это те, которые опровергаются в неподвижной точке. Проведенные эксперименты [21] показывают, что данный критерий

успешно находит неподвижные точки даже при неполной информации об объектах.

Заключение

Приведенные результаты позволяют предположить, что на основе отражения мозгом максимально специфических причинно-следственных связей и возникающих неподвижных точек можно создать математически точную модель отражения мозгом реальности, проявляющуюся в сознании. Для этого достаточно уметь точно отражать причинные связи с помощью максимально специфических причинных связей. Можно показать, что отражение мозгом максимально специфических причинно-следственных связей позволяет моделировать множество когнитивных функций в соответствии с существующими физиологическими и психологическими теориями. Организация целенаправленного поведения моделируется причинно-следственными связями между действиями и их результатами [22], которые полностью соответствуют теории функциональных систем [23]. Неподвижные точки адекватно моделируют восприятие [21]. Набор причинно-следственных связей моделирует экспертные знания [24].

Список литературы

1. Tononi G. An information integration theory of consciousness // BMC 2004. Neurosci 5:42.
2. David Balduzzi, Giulio Tononi. Integrated Information in Discrete Dynamical Systems: Motivation and Theoretical Framework // PLoS Computational Biology. 2008. 4(6). 2–18.
3. Ozumi M., Albantakis L., Tononi G. From the Phenomenology to the Mechanisms of Consciousness: Integrated Information Theory 3.0 // PLOS Computational Biology. 2014 May. V. 10. Issue 5.
4. Carnap R. Philosophical Foundations of Physics. Basic Books. 1966.
5. Hempel C. Aspects of Scientific Explanation // Aspects of Scientific Explanation and other Essays in the Philosophy of Science. The Free Press: New York. 1965.
6. Hempel C. Maximal Specificity and Lawlikeness in Probabilistic Explanation // Philosophy of Science 1968, 35, 16–33.
7. Vityaev E. The logic of prediction // Mathematical Logic in Asia. Proceedings of the 9th Asian Logic Conference, Novosibirsk, Russia, August 16-19, 2005. Goncharov, S., Downey, R., Ono, H., Eds. World Scientific: Singapore. 2006. P. 263-276.
8. Vityaev E., Odintsov S. How to predict consistently? // Trends in Mathematics and Computational Intelligence. Studies in Computational Intelligence. 2019. Vol. 796. P. 35-41.
9. Vityaev E. A formal model of neuron that provides consistent predictions // Biologically Inspired Cognitive Architectures 2012. Proceedings of the Third Annual Meeting of the BICA Society (Chella, A., et al. eds.). Advances in Intelligent Systems and Computing, V. 196, Springer. 2013. P. 339-344.

10. Найсер У. Познание и реальность. Москва: Прогресс. 1981, 229 с.
11. Mill J. System of Logic, Ratiocinative and Inductive. L. 1983.
12. Смирнов Е.С. Конструкция вида таксономической точки зрения // Зоол. Журн. 1938. Т. 17, № 3. С. 387–418.
13. Ganter B. Formal Concept Analysis: Methods, and Applications in Computer Science. TU: Dresden, Germany. 2003.
14. Vityaev E., Demin A., Ponomaryov D. Probabilistic Generalization of Formal Concepts // Programming and Computer Software. 2012. 38:5, 219–230.
15. Vityaev E., Martinovich V. Probabilistic Formal Concepts with Negation // PCI 2014, Voronkov A., Virbitskaite I., Eds., LNCS 8974. 2015. P. 385-399.
16. Витяев Е.Е., Мартынович В.В. Формализация "естественной" классификации и систематики через неподвижные точки предсказаний // Сибирские электронные математические известия (Siberian Electronic Mathematical Reports), Том 12, Институт математики им. С. Л. Соболева СО РАН. 2015. С. 1006–1031.
17. Rosch E. Natural categories // Cognitive Psychology. 1973. 4, 328–350.
18. Rosch E. Principles of Categorization // Cognition and Categorization, Rosch, E., Lloyd B., eds.; Lawrence Erlbaum Associates, Publishers: Hillsdale. 1978. P. 27–48.
19. Rehder B. Categorization as causal reasoning // Cognitive Science. 2003. 27, 709–748.
20. Rehder Bob, Martin J. Towards A Generative Model of Causal Cycles // 33rd Annual Meeting of the Cognitive Science Society 2011, (CogSci 2011), Boston, Massachusetts, USA, 20-23 July 2011. V.1, P. 2944–2949.
21. Витяев Е.Е., Неупокоев Н.В. Формальная модель восприятия и образа как неподвижной точки предвосхищений // Подходы к моделированию мышления. М.: УРСС Эдиториал. 2014. С. 155–172.
22. Vityaev E. Purposefulness as a Principle of Brain Activity // Anticipation: Learning from the Past 2015. Ed. Nadin, M., Cognitive Systems Monographs, V.25, Chapter No.:13, Springer. P. 231–254.
23. Anokhin P.K.: Biology and neurophysiology of the conditioned reflex and its role in adaptive behaviour 1974, Oxford etc.: Pergamon press. P. 574.
24. Vityaev E., Perlovsky L., Kovalerchuk B., Speransky S. Probabilistic dynamic logic of cognition // Biologically Inspired Cognitive Architectures 2013. Special issue: Papers from the Fourth Annual Meeting of the BICA Society (BICA 2013). V. 6. P. 159–168.

A. L. PROSKURA, S. O. VECHKAPOVA, A. S. RATUSHNYAKThe Institute of Computational Technologies of SB RAS, Novosibirsk, Russia
annleop@mail.ru**DOPAMINE AND HIPPOCAMPAL SYNAPTIC PLASTICITY**

In addition to its role in learning and memory formation, the hippocampus may act as a novelty detector. Hippocampal synaptic plasticity has been implicated in both spatial memory formation as well as novelty acquisition. In addition, the ventral tegmental area-hippocampal loop has been proposed to control the entry of information into long-term memory, whereas the dopaminergic system is believed to play an important role in information acquisition and synaptic plasticity. Physiological and behavioral evidence supports that dopamine receptor signaling influences hippocampal function. Hippocampal synaptic plasticity, in the form of long-term potentiation and long-term depression, has been implicated in both spatial memory formation as well as novelty acquisition. However, the molecular mechanisms of synaptic plasticity modulation by dopamine in the hippocampus remain poorly understood. The aim of this study was to achieve a better understanding of the functional association between glutamate and dopamine receptors on synapses of hippocampal CA1 field. The functional association ionotropic and metabotropic receptors facilitate synaptic plasticity processes in hippocampus. The dopaminergic system gates long-term changes in synaptic strength and these changes are a critical factor in the acquisition of novel information.

Keywords: hippocampus, dopamine, dopamine receptors, glutamate receptors, long-term potentiation.

Introduction

Learning and memory are mediated by changes in the excitability of the cell and modulations of synaptic transmission, usually it take place in protein system of the postsynaptic part of a synapse – the dendritic spines. The interactome of dendritic spine (a set of all protein interactions with each other) represents a dynamic multi-level and multi-component system [1].

Receptors for dopamine (DA) have been classified into two functional types, D1 and D2. They belong to the family of receptors acting through G (or guanine nucleotide-binding) proteins. D1 receptors (D1/5 receptors) stimulate adenylyl cyclase and activate cyclic AMP-dependent protein kinases. D2 receptors inhibit adenylyl cyclase. Dopamine D1 and D2 receptors are targets of drug therapy in many psychomotor disorders, including Parkinson's disease, Huntington's disease, schizophrenia, and may also have a role in drug addiction and alcoholism [2].

Physiological and behavioral evidence supports that dopamine (DA) receptor signaling influences hippocampal function. Hippocampal synaptic plasticity, in the form of long-term potentiation (LTP) and long-term depression (LTD), has been implicated in both spatial memory formation as well as novelty acquisition. However, the molecular mechanisms of synaptic-plasticity modulation by dopamine in the hippocampus remain poorly understood. In this work we offer the reconstruction of molecular events that underlie the association of glutamate and dopamine receptor signaling on hippocampal synapses.

Molecular functional system of hippocampal glutamate receptors

Ionotropic glutamate receptors (NMDA (N-methyl-D-aspartate), AMPA (α -amino-3-hydroxy-5-methyl-4-isoxazolepropionic acid) receptors) are key components of exciting synapses into a brain. Through structural proteins of postsynaptic density (PSD) they form various synaptic protein macrocomplexes [3].

Local fast NMDAR-mediated entering of calcium ions starts up the cascades of intermolecular rearrangements and forms the functional regulatory molecular networks causing the change of density of AMPA receptors (AMPA) in a zone of synaptic contact. Long-term potentiation (LTP) provides a commonly accepted in vitro model of synaptic plasticity and consists in a persistent increase in synaptic efficiency.

In the CA1 field of the adult hippocampus, AMPAR is represented by tetramers of dimers of the GluR1, GluR2, GluR3 subunits. Basic neurotransmission and induction of LTP depend on AMPAR, which includes the subunits GluR2 and GluR3 (GluR2-AMPA). After induction of LTP, the internalization of GluR2-AMPA and the introduction of the GluR1-AMPA, which includes the subunits GluR1, into the synapse zone takes place [4,5].

In order that GluR1-AMPA could enter a synaptic membrane of a spine, they should be phosphorylated on serine S845 of the carboxyl cytoplasmic domain by cAMP-dependent protein kinase (PKA) which, in turn, is activated by locally synthesized cAMP (cyclic adenosine monophosphate) [6]. The synthesis of cAMP is carried out due to an adenyl cyclase which is locally anchored on a synaptic membrane. The cAMP molecules are rapidly disintegrated by phosphodiesterase. Thus, the spatial approaching of GluR1-AMPA, the source of cAMP and PKA through structural proteins of PSD, plays, that is an obvious, the crucial role for success in anchoring these receptors in the synaptic membrane (Fig. 1).




Fig. 2. Scheme of GluR1-AMPA receptor density changes at synapses after NMDAR-mediated LTP induction: 1. NMDAR-mediated Ca^{2+} -ions entering; 2. Ca^{2+} -mediated activation of ADCY8 and raise of cAMP pool; 3. cAMP-mediated activation of PKA which anchoring on postsynaptic density after LTP induction; 4. PKA phosphorylated of GluR1-AMPA on serine S845; 5. GluR1-AMPA entering and anchoring on postsynaptic density. ■ - GluR1-AMPA; ▒ - GluR2-AMPA; ▭ - NMDAR; S - serine S845 of the GluR1-AMPA carboxyl cytoplasmic domain; Ca^{2+} - Ca^{2+} -ions; ADCY8 - Adenylyl cyclase type 8; cAMP - cyclic adenosine monophosphate; PKA - cAMP-dependent protein kinase; PSD - postsynaptic density.

There are constitutively active adenylyl cyclases, as well as those whose activity depends on the entering calcium ions - ADCY8 (Adenylyl cyclase type 8). ADCY8 is expressed on the neurons of the hippocampal CA1 field at a high level, and co-localized with the NMDAR [7]. Thus, on hippocampal synapses, the macrocomplex of proteins is formed, which ensures the synaptic input of GluR1-AMPA after induction of LTP and NMDAR-mediated synaptic calcium entry (Fig. 1).

Dopamine regulation of hippocampal synaptic plasticity

It is known that DA modulates the synaptic plasticity in a hippocampus and promotes training [8-10]. The dopaminergic system, acting through DA receptors (DAR), gates long-term changes in synaptic strength (reduces the threshold of LTP induction) and these changes are a critical factor in acquisition of new information.

The quantitative immunogold results revealed a higher labelling density of Dopamine D5 receptors (D5R) on hippocampal dendritic spines, notably at their synaptic membranes, compared to pyramidal cell somas and dendrites [11].

D5R (the D (1B) dopamine receptor, coding *Drd5* gene) belongs to Gs pro-

tein-coupled receptors. Gs enhance the activity of some adenylyl cyclases.

ADCY1 (Adenylate cyclase type 1, coding ADCY1 gene) is expressed predominantly in brain and catalyzes the formation of cAMP in response to Gs-protein signaling and mediates responses to increased cellular Ca^{2+} /calmodulin levels [7]. Mice which ADCY1 was inactivated by mutagenesis, demonstrated the abnormality of synaptic responses and LTP expression in the hippocampal CA1 field. Although mutant mice learned but there were problems with spatial memory [12]. Introduction of the DAR antagonist directly during training, but not three hours after training, prevented the formation of long-term memorization without affecting the non-spatial memory and did not disturb the normal functioning of the hippocampus [9].

Thus, it is obvious that DA modulates the synaptic activity in the hippocampus and in the CA1 field, in particular. It can be assumed that DA through ADCY1 activity may raise the density of AMPAR after activating NMDAR and calcium ions entering due to increased of the pool of phosphorylated GluR1-AMPA on S845 (Fig. 2).




Fig. 2. Scheme of functional association of a signaling from glutamate and dopamine receptors after NMDAR-mediated LTP induction: 1. NMDAR-mediated Ca^{2+} -ions entering; 2. Ca^{2+} and Gs mediated activation ADCY1 and additional cAMP pool growth; 3. cAMP-mediated activation of PKA which anchoring on postsynaptic density after LTP induction; 4. PKA phosphorylated of GluR1-AMPA on serine S845; 5. more GluR1-AMPA enter and anchoring on postsynaptic density. ■ - GluR1-AMPA; ■ - GluR2-AMPA; □ - NMDAR; S - serine S845 of the GluR1-AMPA carboxyl cytoplasmic domain; Ca^{2+} - Ca^{2+} -ions; G - Gs protein; D5R - D (1B) dopamine receptor; ADCY8 - Adenylate cyclase type 8; ADCY1 - Adenylate cyclase type 1; cAMP - cyclic adenosine monophosphate; PKA - cAMP-dependent protein kinase; PSD - postsynaptic density.

This may explain reduces the threshold of LTP induction in hippocampal synapses. The blockade of NMDAR did not prevent the effect of DAR, but it also required the entry of calcium ions into the cell [8]. This indicates the association of signaling between receptors, and not their physical interaction.

Conclusion

In order that the coming signal was perceived and remembered as new, the functional association of a signaling from two types of receptors on a synapse – ionotropic glutamate, NMDAR, and metabotropic dopamine, D5R is necessary. D5R starts an additional contour of cAMP production, modulating thus the introduction of AMPAR to a synapse which is controlled by the NMDAR macro-complexes.

References

1. Proskura A.L., Ratushnyak A.S., Vechkapova S.O., Zapara T.A.: Synapse as a multi-component and multi-level information system // Kryzhanovsky B., Dunin-Barkowski W., Redko V. (eds). Advances in neural computation, machine learning, and cognitive research. NEUROINFORMATICS 2017. Studies in computational intelligence, vol. 736, pp.186–192. Springer, Cham. (2018)
2. Sunahara R.K., Niznik H.B., Weiner D.M., Stormann T.M., Brann M.R., Kennedy J.L., Gelernter J.E., Rozmahel R., Yang Y.L., Israel Y., [et al.]. Human dopamine D1 receptor encoded by an intronless gene on chromosome 5 // Nature 347(6288), 80–83 (1990).
3. Proskura A.L., Zapara T.A. Function and Molecular Design of the Synapse. In: Kryzhanovsky B., Dunin-Barkowski W., Redko V. (eds) Advances in Neural Computation, Machine Learning, and Cognitive Research // NEUROINFORMATICS 2018. Studies in Computational Intelligence, vol. 799, pp. 334–338 Springer, Cham. (2018).
4. Newpher T.M., Ehlers M.D. Glutamate receptor dynamics in dendritic microdomains // Neuron 58(4), 472–497 (2008)
5. Tanaka H., Hirano T. Visualization of subunitspecific delivery of glutamate receptors to postsynaptic membrane during hippocampal long-term potentiation // Cell. Rep. 1(4), 291–298 (2012).
6. Mons N., Guillou J.L., Decorte L., Jaffard R. Spatial learning induces differential changes in calcium/calmodulin-stimulated (ACI) and calcium-insensitive (ACII) adenylyl cyclases in the mouse hippocampus // Neurobiol. Learn. Mem. 79(3), 226–235 (2003).
7. Wei F., Qiu C.S., Kim S.J., Muglia L., Maas J.W., Pineda V.V., Xu H.M., Chen Z.F., Storm D.R., Muglia L.J., Zhuo M. Genetic elimination of behavioral sensitization in mice lacking calmodulin-stimulated adenylyl cyclases // Neuron 36(4), 713–726 (2002).
8. Yang S.N. Sustained enhancement of AMPA receptor- and NMDA receptor-mediated currents induced by dopamine D1/D5 receptor activation in the hippo-

- campus: an essential role of postsynaptic Ca^{2+} // *Hippocampus* 10(1), 57–63 (2000).
9. Da Silva, W.C., Köhler, C.C., Radiske, A., Cammarota, M. D1/D5 dopamine receptors modulate spatial memory formation // *Neurobiol Learn Mem.* 97(2), 271–275 (2012).
 10. Bartsch J.C., Fidzinski P., Huck J.H., Hörtnagl H., Kovács R., Liotta A., Priller J., Wozny C., Behr J. Enhanced dopamine-dependent hippocampal plasticity after single MK-801 application // *Neuropsychopharmacology.* 40(4), 987–995 (2015).
 11. Medin T., Owe S.G., Rinholm J.E., Larsson M., Sagvolden T., Storm-Mathisen J., Bergersen L.H. Dopamine D5 receptors are localized at asymmetric synapses in the rat hippocampus // *Neuroscience* 192, 164-171 (2011).
 12. Wu Z.L., Thomas S.A., Villacres E.C., Xia Z., Simmons M.L., Chavkin C., Palmiter R.D., Storm D.R. Altered behavior and long-term potentiation in type I adenylyl cyclase mutant mice // *Proc Natl Acad Sci USA* 92(1), 220–224 (1995).

T. A. PALIKHOVA

Lomonosov Moscow State University
palikhova@mail.ru

EUGENE SNAIL: SOMATOSENSORY MAPS ON THE BRANCHES OF SINGLE NEURON OF LAND SNAIL

The cognitive maps of the brain are present one of the main themes of neuroinformatics. Penfield's homunculus is the classic example of presentation of sensory and motor body fields in the human cortex. In analogy with Penfield homo a term Eugene snail means a presentation of body fields at the branches of single neurons. The term was proposed in memorial of E. N. Sokolov known for his studies of information processing in the brain. The data presented here were obtained using intracellular recording and imaging of the identified neurons of land snail. We propose new level for cognitive maps distribution – the branches of single neurons.

Keywords: sensory and motor maps, identified neuron, neuronal branches, intracellular activity.

Introduction

The cognitive maps in the brain present one of the main themes in Neuroinformatics. The mechanisms of presentation of external world in the brain connect closely connect with the problems of function localization and neuronal nets organization. Penfield's homunculus is the classic example of sensory and motor field presentation in human cortex [1, 2]. Modern neurobiological methods such as visualization of neuronal activity are used for presentation of the body and other external objects in the brain [3, 4].

Similarly to Penfield homo a term Eugene snail means presentation of sensory and motor maps of body surface of a mollusk. A difference is the presentation the maps on the human cortex and - on the branches of single neurons of a snail. The term Eugene snail was proposed in memorial of Evgeni N. Sokolov – world known scientist proposed psychophysiological concept “man – neuron-model” to study neuronal basics of information processing in the brain [5, 6]. He was the head of department of psychophysiology in Moscow University and leded investigations of neuronal mechanisms information processing. At the department headed for a long time by E. Sokolov in Moscow University Such researches were made at the neuronal and synaptic levels. He supported research at neuronal level Simple nervous system of mollusks presents useful neurobiological model to study mechanisms of behavior at the neuronal, synaptic and molecular levels [7]. A book and special issue of scientific journal are devoted to researches were made using the land snail [8, 9]. Utility of snails for neurobiological researches is

the existence of identified neurons.

Identified neurons are the individual neurons with constant functional, electrophysiological properties and morphology in nervous systems of different animals. The maps of ganglia with identified neurons were constructed in the snail's ganglia [10]. The most studied identified neurons are the giant neurons of parietal ganglia known as the command neurons of avoidance behavior of the snail [11]. Command neurons directly connected with the problems of neuronal nets organization and decision making. These neurons have giant receptive fields [12] that correspond to giant receptive fields of neurons of higher animals participating in cognitive functions such as novelty neurons in hippocampus. In neuronal architectures leading behavior organization the command neurons dispose at the tops of neuronal nets. Despite these debates on using of term command neuron prolong for today. Even P. Balaban [11] tries to say interneuron despite of command neuron.

Another advantage of giant snail's neurons is identification of presynaptic neurons mono-synaptically connected to the command cells. Two groups of sensory neurons with local receptive fields were identified in left parietal [14] and in pedal ganglia [Zakharov in 9]. This opened a way to study mechanisms of learning and memory in identified synapses [14].

We present now the experimental data obtained using intracellular recording and imaging of identified neurons and synapses of the snail resulted in proposition of new level of cognitive maps presentations – the branches of single neurons.

Methods

Sensory and motor information processing by identified snail's neurons we process our investigation on all levels of neuronal analysis from behavioral to synaptic. To study electrophysiology of neurons we used classical electrophysiological methods of intracellular recording by glass micro-electrodes filled by potassium chloride or citrate and extracellular recording by paired silver electrodes [Palikhova in 8]. Intracellular staining were made by cobalt and injection. Diffuse retrograde staining of neurons thought nerves were used in addition to intracellular coloring. Different ions were used for simultaneous staining of neurons and nerves by different colors.

Mechanical or electrical stimulation of different regions on snail's skin surface were used in the behavioral experiments and on semi-intact preparations to study receptive and motor field of neurons in experiments with intracellular recording. Movement recording were made in different semi-intact preparations: dissected foot and nervous system - mantle complex with or without viscera. Motor fields of the neurons were studied using movements registration simultaneously with intracellular stimulation of neurons. It was possible to record fine body movements evoked by single action potentials [Aralelov in 8]. Further the

main results are presented.

Results

Receptive and motor fields of the command neuron. Snail avoids mechano-sensory stimuli by local escape of part of body in the place of stimulation of later by whole body retraction allow animal to close in the shell [Zakharov in 8]. It is difficult to distinguish between early stage of avoidance behavior and an orienting reaction. The command neurons in the parietal ganglia have the same as whole animal receptive field despite of frontal part of the body. Detailed studying of the receptive fields of the command neurons had been made by E.D. Shekher [8, 12]. The motor field of the command neurons are giant as the sensory fields. Intracellular stimulation of these neurons by current injection evoked movement practically in all parts of the snail's body. It's focus – mantel around respiratory hole the movements have lowest threshold – single action potentials. Data on the command's neurons morphology help to explain this.

Morphology of the command neurons. Intracellular staining of the command showed that all of them have axonal branches directly follow pallial and anal nerves and to the pleural and later pedal ganglia. Individual differences in morphology was compensated by number of similar command neuron (five were identified) for main for life behavior of an animal. Intracellular staining data were confirmed by retrograde injection (Fig. 1).

Snail's neurons receive inputs from other cell trough fine branches along axons. Like dendrites in higher animals these fine branches have postsynaptic receptor activated by mediator from presynaptic and sensory in the list neurons.




Fig. 1. Identified neurons of land snail *Helix pomatia* L. Photos and scheme of the snail with names of body parts and internal organs (<https://en.m.wikipedia.org>) (left). Identified neurons LPa3 and LPa5 (middle column) are original examples of neuronal staining by intracellular and retrograde cobalt and nickel injection for light (neuronal soma with axons) and confocal microscopy (dendrite on the branches). Original photos of neurons at the parietal, visceral and pleural ganglia (right), the modified map proposed by A. Kib-

yakov and D. Sakharov, 1978 [10]

The results are presented in Fig. 2. All identified parietal command neurons with giant receptive fields have similar distribution of axonal branches. These follows directly in parietal and anal nerves and through pleural ganglia into pedal ganglia. Existence of several neurons with similar functions and axonal branches stained question about a meaning of such multiplicity. We test this by large statistics on command neuron's morphology in multiple experiments. Our answer was that such multiplicity exists for compensation of possible individual differences in axonal distribution to obtain stability for such important for survival of animal behavior like defensive reflex.

To locate the parts of body in the ganglia and along branches of neurons we use the data obtained by retrograde staining through different nerves. But the main base was morphological and electrophysiological data about identification of sensory neurons with local receptive fields having direct synaptic connections with the command neurons [13]. Such neurons have been identified in left parietal and right pedal ganglia [9, 14]. There are only two groups of presynaptic identified neurons identified in snail's nervous system. So the popular point of view that in the brain all connect with all isn't right. New data obtained in mammals are that neurons having direct synaptic connections present only 10^{-3} of all even for functionally connected cortical regions.

To receive a result of our data we combined original photos of stained neurons with the parts of snail's body from the semi-intact preparations 'dissected foot' (Fig. 2).

Eugene snail model

To summaries the data obtained we use a term "Eugene snail" for presentation of part of the body in nervous system of the snail and on the branches of identified neurons with giant receptive fields (Fig. 3). This skin presentation in snail is an analog of well known Penfield's homunculus but not for another level – branches of single neuron.

Similarly to Penfield's homunculus Eugene snail presents modified in comparing with real body architecture. It has large mantle complex and reduced in size foot. Like in dissected preparation foot on the scheme is divided to right and left half. There is no identity in half's size. This is consist with data on receptive fields of the command neuron where left cells prefer to response to stimulation of left part of foot. Despite of this a question about asymmetry of functions for snail's symmetrical neurons is open.




Fig. 2. The body and neurons of the snail. Left – schemes of semi-intact preparation of a snail – “dissected foot” and parietal ganglion complex with identified giant LPa3 and RPa3 neurons with the axonal branches. Right – two examples of collages from stained LPa3 and RPa3 neurons and a real snail with dissected foot.

Symbols: F – foot. M – mantle, V – viscera, NS – nervous system; RPag, LPag, RPlg, LPlg, RPdg and LPdg – paired right and left parietal, pleural and pedal ganglia and Vg – no paired visceral ganglion. Left and Right Pallial, Intestinal and anal nerves: LPn, RPn, In, An

Identification of only two groups of sensory neuron cannot help to respond the question. Sensory neurons in left parietal ganglion receive input from not symmetrical intestinal organs of the snail [14]. Second group receiving inputs from foot was identified in right pedal ganglion only [Zakharov in 9]. But these data have importance for such questions as information processing and mechanisms of memory at neuronal level.

Location of sensory inputs from different regions of body open new possibility to compare synaptic plasticity in different part of a neuron. Identified synapses of mollusks are of main sources of our understanding of neuronal mechanisms of memory [14]. A possibility exists to compare synaptic dynamics for inputs in different part of a single neuron. A perspective appears to use optogenetic methods to noninvasively record noninvasively intracellular activity in soma and branches of a single neuron.




Fig. 3. Two levels of somatosensory presentation. Penfield's sensory homunculus (left presents human body in somatosensory cortex of human brain proposed by Wilder Penfield [1] with an addition [3]. Eugene snail (right) – presentation of snail's body surface (gray) on the branches of neuron (black) with giant somatosensory receptive field

AI constructors don't means in heads chemical specificity of signal in the brain, once more difference between real brain and AI information processing. But real problem exists about neurotransmitters working in different synaptic inputs. For snails researches long lasting discussion takes place between scientists preferring glutamate or acetylcholine for sensory inputs to the command neurons. Eugene snail model puts out the question and present a possibility to compare plasticity in synapses with different chemical specificity. Our current researches with antagonists of nicotine receptors devote the problem. This is in accordance with modern view on acetylcholine as the main neurotransmitter for cognition [15].

Conclusions

Cognitive processes are studied now by new neurobiological methods with high-resolution in the brain. The experimental data obtained are used, in particular, for creature of artificial intelligence. There is need in new models of information processing in the brain. Spherical model proposed by E.N. Sololov works for all cognitive functions from perception to consciousness [5, 16]. Using psycho-physiological strategy "Human – Neuron – Model" [6] we used identified neurons of the land snail to study fine mechanism of sensory and memory processing on neuronal and synaptic levels. Results obtained are for presentation of skin surface in nervous system and on neuronal branches of the snail and show general topological principle of somatosensory coding. These coincide with somatosensory maps in human cortex but unlike Penfield' homunculus Eugene snail presents new level of somatosensory presentation – branches of a single neuron.

References

1. Penfield W., Rasmussen T. R. The cerebral cortex of man // New York. NY26: the Macmillan Comp. 1950. V. 44. N56. P. 214-15 doi:10.1093/brain/awx270
2. Catani M. A little man of some importance // Brain. 2017. V. 140, N 11. P. 3055-3061. DOI: 10.1093/brain/awx270 10.1093.brain
3. Snyder P., Whitaker H. Neurologic Heuristics and artistic whimsy: The cerebral cartography of Wilder Penfield // J. of history of the neurosciences. 2013. V. 22. N 3. DOI:10.1080/0964704X.2012.757965.
4. Hanger M. The visual representation of cerebral process // The Body Within: Art, Medicine and Visualization. Val R. and Zwijnenberg R. (Eds.) BRILL, 2009, Ch.3, P. 67-91. ISBN 900417617.
5. Sokolov E.N. Model of cognitive processes // Advances in Psychological Science. Vol.2. Biological and cognitive aspects. Eds.: Subourin M., Clark F., Hova R.M. // Psychological Press Ltd, publishers. 1998. P. 355-379.
6. Human – Neuron – Model. International scientific conference in memory of E.N. Sokolov and Ch.A. Izmailov. 19–20aug. 2016 // Abstract book. Moscow, Russia, M.V. Lomonosov MSU. 2016. 256 p.
7. Kerkut G.A. The use of snail neurons in neurophysiological studies // Endeavour. 1969.
8. Neurocybernetic analysis of mechanisms of behavior (“Voprosi kibernetiki” in Russian) Eds.: E.N. Sokolov and L.A. Shmelev. Russia, Moscow. Nauka. 1985. 209 p.
9. Neurobiology of snail *Helix pomatia*. Special issue of Zh.Vyssh.Nerv.Diat.im. I.P. Pavlov // Neurosci. Comp. Physiol. 1994. V24 (1992 Nov-Dec. V. 42, N 6 in Russian).
10. Ierusalimski V.N., Zakharov I.S., Palikhova T.A., Balaban P.M. Nervous system and neural maps in Gastropod *Helix lucorum* L. // Neurosci. Comp. Physiol. 1994, V. 24, pp. 13-22.
11. Balaban P.M. A system of command neurons in snail's escape behavior // Acta Neurobiol. Exp. 1979. V. 39. P. 97-107.
12. Shekhter E.D., Arakelov G.G. Receptive field of command neuron // Neurocybernetic analysis of the mechanisms of behavior. Eds: E.N.Sokolov and L.A. Shmelev. Russia, Moscow. Nauka.1985. P. 64–84 (in Russian).
13. Arakelov G.G., Marakujeva I.V., Palikhova T.A. Structural and functional analysis of monosynaptic connections between identified neurons of *Helix lucorum* // Simpler nervous systems. Eds.: D.A. Sakharov and W. Winlow. Manchester University Press. 1991. P. 258–269.
14. Palikhova T.A. Neurons and synapses of land snail in vector psychophysiology of E.N. Sokolov // Vestnic of Moscow University. Sect. Psychology 14. 2010. N 4. P. 150-164 (in Russian).
15. Lendvai B., Kassai F., Szjli A., Nmethy Z. $\alpha 7$ Nicotinic acetylcholine receptors and their role in cognition // Brain Research Bulletin. 2013. V. 93. P. 86– 96
16. Sokolov E.N. The Psychophysiology of consciousness. Eds.: A.M. Chernorizov, K.A. Chernorizov, D.M. Bowden. N.J.: Oxford Univ. Press. 2013. 222 p.

А. К. КРЫЛОВ

Институт психологии РАН, Москва
neuru@mail.ru

МОДЕЛЬ ФОРМИРОВАНИЯ КОЛОНОК НЕЙРОНОВ КОРЫ КАК СПОСОБ МЕТАБОЛИЧЕСКОЙ КООПЕРАЦИИ И КОНКУРЕНЦИИ*

Активность нейронов рассмотрена как способ получения ими метаболитов через кровоток. В соответствии с известными данными BOLD fMRI совместная активность нейронов колонки рассматривается как способ метаболической кооперации – расширяя капилляр, посредством активации глиальных клеток, усиливает приток метаболитов в колонку. Построена модель формирования колонок нейронов в коре мозга с кооперацией внутри колонки и конкуренцией между колонками.

Ключевые слова: активность, нейрон, корковая колонка, метаболизм.

Введение

На основе парадигмы реактивности мозг рассматривается как обработчик входной информации из внешней среды, по аналогии с компьютером [1]. Ролью нейрона, как и мозга в целом, в соответствии с «вычислительной метафорой», считается перекодирование входного сигнала в выходной (обзор развития представлений о мозге см. в [2–5]). В этой парадигме реактивности работа слоев коры мозга рассматривается как преобразование матрицы входных сигналов в матрицу активности этого слоя нейронов, а работа корковой колонки как детектор некоторых локальных свойств входного сигнала, как, например, ориентации линий [6].

Парадигма реактивности применительно к работе мозга подвергается критике в психологии и психофизиологии и в качестве альтернативы рассматривается парадигма активности, основанная на представлениях о целенаправленности [2–5, 7–11]. Парадигма активности рассматривает активность любой клетки или целого организма как способ достижения цели – нового соотношения со средой [2–4, 7]. На уровне нейрона спайковая активность рассматривается как способ получить необходимые метаболиты от соседних клеток [2, 7–9]. Есть биохимические основания, применяя парадигму активности к нейрону [2, 7], считать, что активность нейрона приводит к усилению притока метаболитов к нему и после завершения

* Работа выполнена по государственному заданию ФАНО России №0159-2019-0001.

активности позволяет оказаться в фазе энергетической «сверхкомпенсации» – получить метаболический бонус за свою активность, который существенно превышает расходы на нее [7, 12–14].




Рис. 1. Биологические процессы, происходящие при воздействии на нейрон или при активации нейрона. Глутамат выходит из синаптической щели и захватывается (1) глиальной клеткой, что приводит к ее активации; либо активация нейрона, меняя ионный состав в среде, активирует глиальную клетку (8). Активация глиальной клетки воздействует на капилляр (2), он расширяется (3), что увеличивает приток метаболитов к глиальной клетке (4) и в эту область. Глиальная клетка выделяет глутамин, который захватывается пресинапсом (5), лактат и прочие метаболиты захватываются нейроном (6) и усиливают энергопродукцию нейрона (7)

Физиология этого механизма, применительно к нейронам коры, представляется следующей. Активация нейрона приводит не только к генерации спайков и движению токов по аксону, но и к активации соседних глиальных клеток, которые получают метаболиты (глюкозу) из кровотока и снабжают метаболитами (лактат и пр.) активный нейрон (рис.1) [15, 16]. Пресинаптический выброс глутамата не только может активировать постсинаптический нейрон. Глутамат вытекает из синаптической щели и поступает в ближайшую глиальную клетку (астроцит) (рис.1, стрелка 1) которая, затем выделяет метаболиты – глутамин, лактат, АТФ и интермедиаты цикла Кребса, поступающие в синапсы и нейроны (рис. 1, стрелки 5, 6) [12, 13, 15, 16]. Поэтому и медиаторное воздействие на нейрон, и активация нейрона способствуют притоку метаболитов к нему. При этом глиальные клетки в этой микрообласти расширяют капилляр и усиливают кровоток в эту область и так усиливают приток метаболитов [12–17]. Поэтому приходящие к нейрону «возбуждения» активируют локальный кровоток и приводят к получению «возбуждающимся» нейроном метаболитов

тов. В настоящее время рассматриваются три причины получения метаболического «бонуса» нейроном: активация нейрона приводит к активации глиальных клеток (рис.1, стрелка 8) [18]; выделение глутамата из пресинапса с его захватом глиальной клеткой возможно даже, без активации самого нейрона (рис.1, стрелка 1) [16]; получение метаболитов неактивными нейронами соседних колонок, лежащими в этой области (рис.1, стрелка 6) [17, 19, 20], хотя меньше, чем нейронами активной колонки [21]. Таким образом, получение метаболического бонуса предположительно возможно за счет: а) входного воздействия; б) собственной активности нейрона; в) активности «соседних» нейронов. Если рассматривать получение метаболитов не одним нейроном, а корковой колонкой, описанный механизм означает, что она может получать метаболический бонус за счет: а) входных воздействий, независимо от собственной активации; б) собственной активности колонки; в) за счет активности «соседних» колонок.

Весь мозг не может одновременно усилить приток метаболитов всем нейронам, поскольку приток метаболитов ограничен. Необходима некоторая последовательность и организация «запросов» на дополнительное метаболическое обеспечение. Можно предполагать, что такая организация обеспечивается благодаря поведенческой специализации нейронов при обучении [9–11] – нейрон становится активным только при решении определенной поведенческой задачи, своей активностью обеспечивает совершение определенного поведенческого акта (относительно которого нейрон специализировался). Тогда усиленный приток метаболитов получают именно те нейроны, которые работают в данной задаче, обеспечивая совершение текущего поведенческого акта [7, 12, 13, 17]. Следовательно, именно совершаемым поведенческим актом определяется, какие нейроны получают дополнительные метаболиты во время и после своей активности.

Известно, что корковые колонки находятся в оппонентных отношениях, не активируются одновременно, так что именно активная колонка получает метаболический бонус [17, 21–24] (рис. 2). При этом нейроны одной колонки могут активироваться одновременно, поэтому в метаболическом смысле находятся в кооперативных отношениях (рис. 2, слева). Разные колонки, находящиеся в одной области, находятся в конкурентных отношениях за метаболиты, поскольку снабжаются из одного капилляра или из соседних капилляров, имеющих общий исток (рис. 2, справа).

Модель

Задачей моделирования было изучить возможность формирования колонок синхронно работающих нейронов на основе принципов метаболической конкуренции и кооперации за общий приток метаболитов, как следствие активности этих нейронов. В модели имелось 8 колонок по 4 нейрона (слоя) в каждой, имеющие общий метаболический источник (ка-

пилляр или их микросеть) (рис. 3). Активация нейронов одной колонки усиливала приток метаболитов к этой колонке. В этой версии модели считалось, что все метаболиты получает только наиболее активная колонка, т.е. та, в которой больше нейронов синхронно активируются в данной задаче. Всего было 8 задач (ситуаций). Каждый нейрон мог специализироваться под любую задачу, т.е. постоянно активироваться в ней, а значит, допускалась возможность специализации нейрона под несколько задач.




Рис. 2. Метаболическая кооперация и конкуренция корковых колонок. Слева: активация нейронов колонки приводит к активации близлежащего астроцита (1), который расширяет капилляр (2), что приводит к притоку кислорода в эту область (3) и притоку глюкозы в этот астроцит (4), который затем трансформируется в лактат и передается нейронам (1). Справа: несколько корковых колонок конкурируют за приток метаболитов из капилляра, поскольку находятся в оппонентных отношениях




Рис. 3. Иллюстрация к модели формирования специализации нейронов в корковых колонках. Вверху: всего 8 задач (ситуаций). Внизу: рассматривалось 8 колонок по 4 нейрона (слоя) в каждом. Каждый нейрон мог специализироваться под любую задачу. Все колонки конкурируют за общий источник метаболитов (обо-

значен как капилляр слева)

На каждом такте времени выбиралась случайная задача, и один из 8 входов сети активировался, обозначая текущую ситуацию. Предполагалось, что задача может быть решена нейронами любой колонки. Каждый i -й нейрон активировался в соответствии с величиной N_{ij} , где i – номер нейрона, j – номер задачи, равный текущей задаче. Начальное значение N_{ij} равнялось 0,5. Далее вычислялась наиболее активная колонка, по сумме значений активаций ее нейронов, которая и получала метаболическое «подкрепление», что аналогично сигналу подкрепления в reinforcement learning. Нейроны этой колонки, которые были активны, увеличивали вероятность вовлечения в эту задачу – величина N_{ij} у них возрастала:

$$N_{ij} = N_{ij} + 0.3 * (1 - N_{ij})$$

Нейроны этой колонки, которые не были активны, а также нейроны других колонок снижали вероятность вовлечения в эту задачу:

$$N_{ij} = N_{ij} + 0.5 * (0.05 - N_{ij})$$

Когда вероятность N_{ij} вовлечения в задачу j оказывалась выше порога 0.95, N_{ij} фиксировалась на уровне 1, что означало необратимую специализацию нейрона к этой задаче [9, 10]. С учетом целей данной работы в модели не рассматривалось полноценное взаимодействие со средой и считалось, что любое действие всегда успешно. В более развитом варианте модели следует учесть достижение результата – решения этой задачи j .

Результаты

После нескольких тысяч итераций модель приходит к стабильному состоянию – часть нейронов специализируется (пример в таблице 1 и на рис. 4; другой пример в таблице 2). Все нейроны одной колонки специализируются к одной задаче, т.е. кооперативно работают для получения метаболического бонуса для своей колонки. Некоторые колонки специализируются под несколько задач, некоторые колонки остаются в резерве.

Таблица 1

Результаты работы модели

Слой	Номер нейронной колонки							
	1	2	3	4	5	6	7	8
1	-	3	58	467	1	-	-	2
2	-	3	58	467	1	-	-	2
3	-	3	58	467	1	-	-	2
4	-	3	58	467	1	-	-	2




Рис. 4. Пример работы модели – описание специализаций нейронов под номера задач. Вверху: результат работы одного из прогонов модели. Внизу: иллюстрация. Видно, что все нейроны одной колонки специализируются под один набор задач, т.е. работают кооперативно. Некоторые колонки специализировались под несколько задач, некоторые – только под одну, некоторые остались в резерве.

Таблица 2

Результаты работы модели

Слой	Номер нейронной колонки							
	1	2	3	4	5	6	7	8
1	1456	7	-	-	-	3	8	2
2	1456	7	-	-	-	3	8	2
3	1456	7	-	-	-	3	8	2
4	1456	7	-	-	-	3	8	2

Выводы

Созданная модель демонстрирует феномен специализации нейронов колонки под определенную задачу, что позволяет им кооперативно работать на достижение общего метаболического результата. Происходит распределение задач между разными колонками, что позволяет им не вступать в одновременную конкуренцию за метаболиты и не мешать работе друг друга. В этой упрощенной модели одна колонка может специализироваться к нескольким задачам одновременно, что может оказаться неэффективно, если требуется эти задачи решать разными способами, а не обобщать в один. Дальнейшее развитие этой модели возможно с учетом

разной дифференциации задач, что потребует более узкой специализации колонок для решения задач разными, несовместимыми способами.

Список литературы

1. Уоссермен Ф. Нейрокомпьютерная техника: теория и практика. Москва: Мир, 1992.
2. Александров Ю.И. Активный нейрон // Нейрон: обработка сигналов, пластичность, моделирование: фундаментальное руководство / под ред. Е. Н. Соколова, Филиппова В.А., Черноризова А.М. Тюмень, 2008. Гл. 2. С. 33–58.
3. Крылов А.К., Александров Ю.И. Парадигма активности: от методологии эксперимента к системному описанию сознания и культуры // Компьютеры, мозг, познание: успехи когнитивных наук / отв. ред. Величковский Б.М., Соловьев В.Д. Москва : Наука. 2008. С. 133–160.
4. Крылов А.К. Поведение и активность нейронов: целенаправленность или реакция // Когнитивные исследования. Сборник научных трудов. Вып.5 – Москва : Изд-во «Институт психологии РАН». 2012. С. 32–43.
5. Сварник О.Е. Активность мозга: специализация нейрона и дифференциация опыта. – Москва : Изд-во «Институт психологии РАН». 2016. 190 с.
6. Шевелев И.А. Нейроны-детекторы зрительной коры. Москва: Наука. 2010.
7. Крылов А.К. Активность нейрона как способ получения метаболитов // XIX Международная научно-техническая конференция "Нейроинформатика–2017": Сборник научных трудов. Ч.1. Москва : НИЯУ МИФИ. 2017. С. 154–163.
8. Анохин П. К. Системный анализ интегративной деятельности нейрона // Очерки по физиологии функциональных систем. Москва, 1975.
9. Швырков В.Б. Введение в объективную психологию. Нейрональные основы психики. Москва, 1995.
10. Александров Ю.И., Горкин А.Г., Созинов А.А., Сварник О.Е., Кузина Е.А., Гаврилов В.В. Консолидация и реконсолидация памяти: психофизиологический анализ // Вопросы психологии. 2015. № 3. С. 133–144.
11. Александров Ю.И., Горкин А.Г., Созинов А.А., Сварник О.Е., Кузина Е.А., Гаврилов В.В. Нейронное обеспечение научения и памяти // Когнитивные исследования : сборник научных трудов. Сер. "Когнитивные науки". Москва : Изд-во «Московский городской психолого-педагогический университет». 2014. С. 130–169.
12. Shetty P.K., Galeffi F., Turner D.A. Cellular links between neuronal activity and energy homeostasis // Front Pharmacol. 2012. Vol. 3:43.
13. Moore C.I., Cao R. The hemo-neural hypothesis: on the role of blood flow in information processing // J. Neurophysiology. 2008. V. 99. P. 2035–2047.
14. Vanzetta I., Grinvald A. Increased cortical oxidative metabolism due to sensory stimulation: implications for functional brain imaging // Science. 1999. V. 286. P. 1555–1558.
15. Riera J.J., Schousboe A., Waagepetersen H.S., Howarth C., Hyder F. 2008. The micro-architecture of the cerebral cortex: Functional neuroimaging models and metabolism // Neuroimage. Vol.40. P. 1436–1459.
16. Magistretti P. J. Role of glutamate in neuron-glia metabolic coupling // Am. J. Clin. Nutr. 2009. Vol. 90. P. 875S–880S.

17. Thompson, J. K., Peterson, M. R., and Freeman, R. D. Single-neuron activity and tissue oxygenation in the cerebral cortex // *Science*. 2003. Vol. 299. P.1070–1072.
18. Erecińska M, Nelson D, Chance B. Depolarization-induced changes in cellular energy production // *Proc Natl Acad Sci USA*. 1991. Vol. 88. P. 7600–7604.
19. Thompson J.K., Peterson M.R., Freeman R.D. Separate spatial scales determine neural activity-dependent changes in tissue oxygen within central visual pathways // *J Neurosci*. 2005. V. 25. P. 9046–9058.
20. Kim D.-S., Duong T. Q., Kim S.-G. High-resolution mapping of iso-orientation columns by fMRI // *Nat. Neurosci*. 2000. V. 3. P. 164–169.
21. Duong T.Q., Kim D.-S., Uğurbil K., Kim S.-G. Localized cerebral blood flow response at submillimeter columnar resolution // *Proc. Natl. Acad. Sci. USA*. 2001. V. 98. P. 10904–10909.
22. Sheth S.A., Nemoto M., Guiou M., Walker M., Pouratian N., Hageman N., Toga A.W. Columnar Specificity of Microvascular Oxygenation and Volume Responses: Implications for Functional Brain Mapping // *J Neurosci*. 2004. V. 24(3). P. 634–641.
23. Woolsey T.A., Rovainen C.M., Cox S.B., Henegar M.H., Liang G.E., Liu D., Moskalkenko Y.E., Sui J., Wei L. Neuronal units linked to microvascular modules in cerebral cortex: response elements for imaging the brain // *Cereb Cortex*. 1996. V. 6. P. 647–60.
24. Wang Z., Roe A.W., Columnar specificity of microvascular oxygenation and blood flow response in primary visual cortex: evaluation by local field potential and spiking activity // *J. of Cerebral Blood Flow & Metabolism*. 2011. P. 1–11.

**М. Ю. ЯРЕЦ¹, Е. В. ШАРОВА¹, М. В. ГАЛКИН²,
Г. Н. БОЛДЫРЕВА¹, А. Ю. КУЛЕВА³, Е. М. ТРОШИНА²,
О. А. КРОТКОВА²**

¹Институт высшей нервной деятельности и нейрофизиологии РАН, Москва

²НИИ нейрохирургии им акад. Н.Н. Бурденко Минздрава РФ, Москва

³Московский государственный университет им. М. В. Ломоносова

marya.yarets@yandex.ru

ОСОБЕННОСТИ ИЗМЕНЕНИЙ ЭЭГ ПРИ ТЕРАПЕВТИЧЕСКОМ ЛУЧЕВОМ ВОЗДЕЙСТВИИ У ПАЦИЕНТОВ С МЕНИНГИОМАМИ МЕДИОБАЗАЛЬНЫХ ОТДЕЛОВ ПРАВОГО И ЛЕВОГО ПОЛУШАРИЙ*

Показана информативность применения анализа пространственной организации когерентных связей ЭЭГ для оценки эффективности радиотерапии у больных с опухолевым поражением правого и левого полушарий мозга. Выявлены особенности реактивности мозга на терапевтическое лучевое воздействие, а также адаптивные стратегии мозга к последствиям лучевой терапии.

Ключевые слова: ЭЭГ, когерентность, лучевая терапия, менингиома.

Введение

К настоящему времени наиболее эффективным способом лечения церебральных опухолей при невозможности хирургической резекции является лучевая терапия. По результатам множества исследований эффективность лучевой терапии соответствует эффективности хирургического лечения: облучение и тотальное удаление опухоли обеспечивают сопоставимый контроль роста новообразования – порядка 80–90% [1, 2].

Вместе с тем биоэлектрические маркеры эффективности лучевой терапии, реактивные изменения нейронных сетей, сопровождающие положительный терапевтический эффект воздействия, а также особенности церебральной нейродинамики при локализации патологического процесса в правом и левом полушариях головного мозга практически не исследованы.

Кроме того, изучение общих реакций мозга на радиотерапию (РТ) является актуальным в связи с возможным развитием нейрокогнитивного дефицита у больных после лечения. Согласно литературе, влияние иони-

* Данная работа выполнена при поддержке РФФИ проект № 17-15-01426.

зирующего излучения на мозг сопряжено с когнитивной дисфункцией, схожей с изменениями при нормальном старении человека и болезни Альцгеймера [3, 4, 5, 6]. Имеются также данные о том, что изменения памяти, внимания, различных видов сенсомоторной деятельности человека в результате чрезмерного ионизирующего облучения представляют собой быструю истощаемость нервной системы, свидетельствующую о снижении резервных возможностей больных [7]. По данным литературы, выявляемый при облучении когнитивный дефицит и прогрессирующий психоорганический синдром могут быть следствием наибольшей “чувствительности” к ионизирующему излучению филогенетически молодых структур головного мозга: коры лобных и височных долей, а также лимбико-ретикулярного комплекса, в том числе структур гиппокампового круга [8].

Цель работы – методом когерентного анализа ЭЭГ исследовать системные реакции мозга пациентов с опухолевым поражением медиобазальных отделов правого или левого полушарий при положительном эффекте РТ (уменьшении объема опухоли).

Задачи работы:

1) Сопоставить особенности ЭЭГ больных до и через 6 месяцев после курса лучевой терапии с целью выявления ЭЭГ- коррелятов положительного эффекта лучевого воздействия на опухоль.

2) Оценить динамику внутриполушарных и межполушарных когерентных связей ЭЭГ по отдельным диапазонам физиологических ритмов у больных с правополушарной и левополушарной локализацией опухоли при положительном эффекте лечения.

Материалы и методы

Основную группу наблюдений составили 15 пациентов с менингиомой медиобазальных отделов правого и левого полушарий. Все они проходили РТ-лечение в отделении радиотерапии и радиохирургии Национального медицинского исследовательского центра нейрохирургии им. акад. Н.Н. Бурденко. РТ-воздействие производилось на аппарате «Novalis» (линейный ускоритель электронов (6 МэВ)). Оно включало 30 терапевтических сеансов, которые проводились подряд по одному сеансу каждый рабочий день.

Разовая очаговая доза (РОД) составила 1,8 Гр в изоцентре, суммарная лучевая доза (СОД) составляла 54 Гр.

Состояние пациентов оценивали в динамике, до и спустя 6 месяцев после РТ, по данным клинического наблюдения, а также МРТ- и ЭЭГ- исследований.

Из 15 пациентов были отобраны 6 больных с положительным эффектом лечения (уменьшением размеров облученной опухоли по данным

МРТ), в возрасте 51–66 лет. У трех из них менингиома была локализована в правом полушарии мозга, и у трех – в левом.

ЭЭГ исследование включало 18-канальную монополярную (относительно ушных референтных электродов) регистрацию биопотенциалов по схеме 10–20% от симметричных затылочных, теменных, центральных, лобных и височных корковых областей с частотой квантования – 100 Гц и полосой пропускания 0.3–35 Гц на базе программно-вычислительного комплекса «Нейрокартограф» (МБН, Россия). Запись проводили в состоянии спокойного бодрствования с закрытыми и открытыми глазами с последующим спектрально-когерентным анализом безартефактных реализаций длительностью не менее одной минуты с «шагом» 0.4 Гц. Акцент в данной работе был сделан на исследовании пространственной организации функциональной коннективности мозга при открывании глаз (ОГ), оцениваемой по показателям когерентности ЭЭГ. Последняя рассчитывалась для всех возможных сочетаний пар отведений по диапазонам основных физиологических ритмов: дельта (0.4–3.9 Гц), тета (4.3–7.4 Гц), альфа1 (7.8–8.6 Гц), альфа2 (9–10.2), альфа3 (10.5–12.5), бета1 (12.9–20.7 Гц) и бета2 (21.1–30.1 Гц). Топографию и достоверность изменений ЭЭГ в фоне при открытых глазах по сравнению с закрытыми определяли с помощью специализированного пакета статистических программ на основе непараметрического критерия Манна–Уитни [9]. Сопоставляли особенности коннективности ОГ пациентов с опухолью головного мозга до и спустя 6 месяцев после лучевой терапии.

Группу контроля составили данные аналогичного исследования у 5 здоровых испытуемых в возрасте 20–26 лет.

Все исследования проведены в соответствии с принципами биомедицинской этики, сформулированными в Хельсинкской декларации 1964 г. и ее последующих обновлениях. От каждого участника исследования было получено добровольное письменное информированное согласие на участие в нем. Исследование проведено согласно принципам Хельсинкской декларации.

Результаты

Анализ пространственной организации когерентных связей при ОГ здоровых испытуемых (рис. 1) показал, что характерными для них являются диффузность изменений коннективности относительно состояния покоя с закрытыми глазами: понижение как внутримушарных, так и межполушарных связей, более выраженное в высоких диапазонах ритмов (альфа-2, альфа-3, бета), наряду с акцентированным в задних корковых областях

(проекции зрительного анализатора) усилением коннективности по более медленным ритмам (дельта, тета и альфа1).




Рис. 1. Изменения когерентности ЭЭГ по диапазонам физиологических ритмов при открытых глазах по сравнению с закрытыми у здоровых испытуемых ($N = 5$)

Толстые линии – значимое повышение когерентности, тонкие – снижение; $p < 0,05$ по критерию Манна–Уитни

В общих чертах эти изменения когерентности ЭЭГ коррелируют с описанными ранее особенностями реакции на открывание глаз в большей выборке здоровых испытуемых [10].

Для оценки особенностей реактивности мозга пациентов до и после лучевого воздействия мы сочли целесообразным проанализировать сначала индивидуальные данные ЭЭГ двух пациентов: с лево- и правосторонней опухолью в динамике наблюдения.




Рис. 2. Пространственная организация когерентных связей при ОГ у пациентки с левосторонней опухолью в динамике наблюдения

I – до РТ, II – через 6 месяцев после.

Толстые линии – значимое повышение когерентности, тонкие – снижение; $p < 0,05$ по критерию Манна–Уитни. Остальные обозначения, как на рис. 1

У пациентки И. (55 лет) с левосторонней локализацией опухоли в исследовании до РТ (рис. 2 I) изменения когерентности ЭЭГ при открывании глаз (по сравнению с фоном с закрытыми глазами) хотя и диффузные, но существенно обеднены по сравнению с нормой. Это касается как числа измененных связей (особенно по высокочастотным, начиная с альфа3, диапазоном), так и их топографии: уменьшение меж- и правополушарной реактивности, редукция ее локального (затылочного) компонента при гиперреактивности левого (“больного”) полушария в форме распространенного усиления связей в тета- и альфа1,2-диапазонах.

На рис. 2, II представлены изменения КогЭЭГ при ОГ спустя 6 месяцев после РТ, сопровождавшейся уменьшением объема левополушарной опухоли. По сравнению с нормой реактивность мозга по-прежнему снижена – особенно межполушарной, а также по высоким (бета1, 2) ритмам. Однако можно отметить ослабление патологической гиперсинхронности биопотенциалов левого (больного) полушария, а также появление изменений КогЭЭГ, присущих норме, в тета-, альфа2- и альфа3-диапазонах: проявилась тенденция к симметричности реагирования с “фокусами” активации в «здоровом», правом, полушарии; более четко выражен локальный «затылочный» компонент реакции.

Рисунок 3 иллюстрирует динамику изменений КогЭЭГ при ОГ у пациентки 3. (66 лет) с правосторонней локализацией опухоли. До начала РТ (рис. 3, I) наблюдается выраженная «обедненность» ЭЭГ-ответа в форме только ослабления функциональных связей по сравнению с закрытыми глазами: ареактивность КогЭЭГ бета-составляющих, ограниченное число изменяющихся диагональных межполушарных связей и отсутствие симметричных.




Рис. 3. Пространственная организация когерентных связей при ОГ у пациентки с правосторонней опухолью в динамике наблюдения:

I – до РТ, II – через 6 месяцев после.

Толстые линии – значимое повышение когерентности, тонкие – снижение; $P < 0,05$ по критерию Манна–Уитни. Остальные обозначения, как на рис. 1

Обращает внимание асимметричность полушарных изменений КогЭЭГ: генерализованное ослабление связей в дельта-диапазоне в «здоровом» в левом и отчетливо фрагментарное, включая локальный «затылочный» компонент реакции в альфа-3 диапазоне, в «больном» правом.

Спустя 6 месяцев после окончания лучевой терапии (рис. 3, II) ответ КогЭЭГ при ОГ существенно меняется: становится более распространенным как по топографии, так и по вовлеченности ритмов, проявляется главным образом в форме усиления связей по сравнению с фоном. Более отчетливо выражен локальный, «затылочный» компонент реакции, в особенности в альфа-1-диапазоне, что приближает реагирование к норме. Хотя в большинстве частотных диапазонов изменения преобладают в «здоровом» левом полушарии, правое («больное») также реактивно в альфа1 и альфа3 диапазонах. Таким образом, по своей пространственной организации ответ КогЭЭГ при ОГ более сходен с нормой после РТ, чем до нее.

В каждой из выборок с лево- и правополушарной локализацией опухоли (по три пациента) была проанализирована динамика изменений реактивности мозга при ОГ до и через 6 месяцев после курса лучевой терапии. Были отмечены определенные различия, сопряженные с латерализацией опухоли.

Так, при *левостороннем поражении* на первый план выступало усиление функциональной асимметрии как компонента реакции на терапевтическое облучение: диффузное снижение когерентности в правом «здоровом» полушарии в дельта- и тета-диапазонах в сочетании с диффузным повышением КогЭЭГ в левой, «больной», гемисфере. Выявлено также усиление участия лобных отделов билатерально (изменения внутриволновых связей) в широком частотном диапазоне. При сохраняющейся в динамике наблюдения ареактивности межполушарных КогЭЭГ наблюдается нарастание реактивности внутриволновых. Обращает на себя внимание реципрокность ЭЭГ-изменений – как между полушариями в одном частотном диапазоне, так и в пределах одной гемисферы, но в разных частотных диапазонах. Например, в левом, «больном», полушарии диффузное усиление когерентности в тета-диапазоне сопровождается также диффузным ее снижением в диапазоне альфа1.

У пациентов с *правосторонним поражением* через 6 месяцев после курса РТ на первый план выступает более выраженная (по сравнению с левополушарным) диффузность ЭЭГ-реакций, чаще в виде гиперсинхронизации КогЭЭГ «здорового» левого полушария, а также межполушарных связей. Наибольшая реактивность отмечена в дельта- и альфа-1-диапазонах ритмов (повышение когерентности). Реактивность бета-

диапазона снижена, чего не наблюдалось у пациентов с левосторонней опухолью. Отмечено усиление когерентности в височных отделах слева, в «здоровой» гемисфере во всех диапазонах ритмов, за исключением бета.

Обсуждение результатов

Проведенное нами пилотное исследование пространственной организации КогЭЭГ при открывании глаз у пациентов с опухолевым поражением головного мозга до и после радиотерапии в сопоставлении с нормой позволило выявить изменения реактивности мозга, обусловленные влиянием лучевого терапевтического воздействия, а также особенностями латерализации патологического процесса. Положительный эффект РТ (уменьшение объема опухоли) сопряжен с тенденцией к “нормализации” ЭЭГ ответа на ОГ на этапе стабилизации состояния (6 месяцев после лечения), что свидетельствует о перспективности использования данного методического подхода для персонифицированной динамической оценки влияния радиотерапии на функциональную активность головного мозга.

Выявленные при этом особенности пространственной организации КогЭЭГ у пациентов с лево- и правополушарной локализацией опухоли – до лечения и в особенности после РТ, указывают на наличие как общих черт, так и различий в системном реагировании мозга на терапевтическое лучевое воздействие. Обращает на себя внимание тот факт, что, независимо от латерализации поражения, общим для пациентов является нарастание реактивности после РТ (в виде повышения КогЭЭГ при ОГ) левого полушария головного мозга: распространенного в пределах полушария у пациентов с правосторонней опухолью; локального, по отдельным частотным диапазонам, при расположении опухоли слева. Это согласуется с отмечаемой ранее большей “чувствительностью” левого полушария к разным формам терапевтических электромагнитных воздействий [11]. Не исключено, что указанные особенности отражают общность реакций мозга человека на внешние волновые влияния, что требует дальнейшего изучения.

Наряду с этим наблюдались и динамические особенности реактивности мозга, сопряженные с латерализацией опухоли. Так, при левостороннем поражении после РТ были отмечены следующие функциональные изменения: усиление реактивности при ОГ лобных отделов, что может быть связано с необходимостью вовлечения большего произвольного контроля при открывании глаз; полушарная реципрокность реагирования, отражающая, вероятно, компенсаторные процессы в результате облучения. В последнем случае «гиперсинхронизация» в левой гемисфере может свидетельствовать о «напряженности» структур “больного” полушария, в то время как в «здоровом» правом проявляется диффузная неспецифическая активация.

Учитывая специфику левого полушария мозга как доминантного, у пациентов с левосторонним поражением мозга при положительном исходе лечения можно предполагать нарастающий когнитивный дефицит, связанный с необходимостью усиления произвольного контроля на фоне недостаточного межполушарного взаимодействия.

У больных с правосторонним поражением функциональные изменения мозга после РТ носят иной характер: диффузное усиление когерентности в большинстве частотных диапазонов (при ареактивности в бета), а также фокус функциональной активности в височных областях левого «здорового» полушария могут отражать компенсаторную стратегию, включающую «напряженность» структур лимбической системы.

Выявленные на основе метода ЭЭГ факты указывают на вероятные различия в адаптивных стратегиях мозга при РТ в зависимости от стороны расположения опухоли. Они требуют проверки и уточнения на большей выборке наблюдений, с привлечением данных нейропсихологического исследования.

Заключение

Полученные результаты свидетельствуют о том, что анализ пространственной организации КогЭЭГ при ОГ представляется «инструментом» для оценки эффективности РХ: независимо от латерализации опухоли при «положительном» эффекте лучевой терапии (уменьшении объема опухоли) пространственная организация КогЭЭГ имеет тенденцию к нормализации на этапе стабилизации состояния пациентов.

В то же время с помощью данного подхода представляется возможным выявление особенностей реактивности мозга, обусловленной как наличием стойкого патологического очага (до лечения), так и эффектов воздействия (после лечения) связанного с латерализацией опухоли. Выявленные нами различия биоэлектрической активности свидетельствуют о правомерности и перспективности не только биоэлектрического, но и нейропсихологического изучения адаптивных стратегий мозга к последствиям РХ.

Список литературы

1. Samuel E. Day, Lia M. Halasz. Radiation therapy for WHO grade I meningioma. // Chinese Clinical Oncology. 2017; 6(Suppl 1):S4.
2. Apra C., Peyre M., Kalamarides M. Current treatment options for meningioma // Expert Review of Neurotherapeutics. 2018. V. 18, N 3. P. 241–249.
3. Жаворонкова Л.А., Гогитидзе Н.В., Холодова Н.Б. Пострадиационные изменения асимметрии мозга и высших психических функций право- и леворуких субъектов // Журнал высшей нервной деятельности им. И.П. Павлова. 2000. Т. 50. № 1. С. 68–79.
4. Lowe X.R., Bhattacharya S., Marchetti F., Wyrobek A.J. Early brain response to low-dose radiation exposure involves molecular networks and pathways associated

- with cognitive functions, advanced aging and Alzheimer's disease // *Radiat. Res.*, 2009. 171(1): 53–65.
5. Алишев Н.В., Свистов А.С., Рыжман Н.Н., Драбкин Б.А., Вашкевич А.А., Николаева Н.А. Показатели биологического возраста и ускоренное старение у ликвидаторов последствий радиационных аварий // *Успехи геронтологии*. 2006. 18: 110–124.
 6. Холодова Н.Б., Жаворонкова Л.А., Рыжов Б.Н., Кузнецова Г.Д. Преждевременное старение организма и особенности его проявления в отдаленный период после облучения малыми дозами // *Успехи геронтологии*. 2007. Т. 20, №4. С. 48–55.
 7. Метляева Н.А., Щербатых О.В. Особенности социальной адаптации участников, пострадавших в результате аварии на атомных подводных лодках К-19 и К-27, по данным психофизиологического обследования // *Медицинская радиология и радиационная безопасность*. 2016. Т. 61, № 1. С. 29–33.
 8. Холодова Н.Б., Рыжов Б.Н., Жаворонкова Л.А. Состояние высших психических функций у участников ликвидации последствий аварии на Чернобыльской АЭС // *Журнал неврологии и психиатрии им. С. С. Корсакова*. Москва: Медиа Сфера, 2005. Т. 105, № 10. С. 57–58.
 9. Воронов В.Г., Щекутьев Г.А., Гриндель О.М. Пакет программ для статистического сравнения записей ЭЭГ. Материалы международной конференции "Клинические нейронауки: нейрофизиология неврология, нейрохирургия", Украина, Крым, Гурзуф, июнь, 2003. 22 – 24.
 10. Шарова Е.В., Болдырева Г.Н., Куликов М.А., Волынский П.Е. ЭЭГ-корреляты состояний зрительного и слухового внимания у здоровых испытуемых // *Физиология человека*. 2009. Т. 35, № 1. С. 5–14.
 11. Шарова Е.В., Гаврилов В.М., Зайцев О.С., Анзимилов В.Л., Соколовская И.Е., Коротаева М.В., Новикова М.Р. Изменения функциональной активности мозга под влиянием ритмической транскраниальной магнитной стимуляции в норме и при посттравматическом угнетении сознания // "Актуальные вопросы функциональной межполушарной асимметрии и нейропластичности" (материалы Всероссийской конференции с международным участием, декабрь 2008 г), Москва : Научный мир, 2008. С. 393–397.

МАТЕРИАЛЫ 2-Й СТЕНДОВОЙ СЕССИИ

М. Г. КУЗЬМИНА, Л. П. БАСС, О. В. НИКОЛАЕВА

Институт прикладной математики им. М. В. Келдыша РАН, Москва
mg.kuzmina@gmail.com; bass@kiam.ru; nika@kiam.ru

О ВОЗМОЖНОСТЯХ МОДЕЛЕЙ ГЛУБОКИХ СВЕРТОЧНЫХ НЕЙРОННЫХ СЕТЕЙ И МНОГО- АГЕНТНЫХ СИСТЕМ В ЗАДАЧАХ ОБРАБОТКИ ГИПЕРСПЕКТРАЛЬНЫХ СПУТНИКОВЫХ ИЗОБРАЖЕНИЙ

Последнее десятилетие наряду с множеством высокоточных традиционных вычислительных методов обработки гиперспектральных спутниковых изображений активно развиваются также нейросетевые подходы, основанные на построении моделей глубоких сверточных нейронных сетей (DCNN) и параллельные адаптивные алгоритмы, основанные на построении моделей много-агентных систем (MAS). В докладе дан краткий обзор современного состояния исследований, содержащих результаты по успешному применению этих подходов в задачах классификации, сегментации и семантической сегментации гиперспектральных изображений.

Ключевые слова: глубокие сверточные сети, много-агентные системы, обработка гиперспектральных спутниковых изображений.

Введение

Обработка спутниковых снимков позволяет получить информацию о многих характеристиках земной поверхности, таких как: минеральный состав открытых горных пород, преобладающий видовой состав растительного покрова (и степени его нарушения), состав, состояние и влажность почвы, местоположения территорий с лесными пожарами, гарями, нелегальными вырубками. Кроме того, обработка спутниковых данных дает возможность определять газовый состав и степень аэрозольного загрязнения атмосферы, создавать карты температуры воздуха, земной поверхности и поверхности водных объектов.

Дистанционное зондирование позволяет получать снимки земной поверхности практически во всех интервалах спектра, доступных съёмке. При восстановлении характеристик земной поверхности по данным дистанционного зондирования для каждого пикселя требуется произвести анализ соответствующей ему спектральной кривой, определяющей долю

отраженного излучения на всем изучаемом интервале спектра (см. рис. 1). Определение характеристик участка земной поверхности, соответствующего пикселю, основано на сравнении пиксельной спектральной кривой с уже известными спектральными кривыми (из собранных "библиотек" для разных объектов земной поверхности).




Рис. 1. Спектральные кривые растительности, почвы и воды

Восстановление характеристик атмосферы и земной поверхности по спутниковым изображениям, как правило, требует решения обратных задач теории переноса излучения. Трудности анализа гиперспектральных изображений связаны с тремя обстоятельствами: 1) высокой размерностью области определения гиперспектральных данных; 2) большим числом спектральных каналов; 3) сложным (сильно изменчивым) поведением спектральных кривых.

При решении обратных задач важное место занимает так называемая атмосферная коррекция – исключение влияния на полученное изображение эффектов, связанных с многократным рассеянием и поглощением света в земной атмосфере.

Наряду с развитым арсеналом традиционных вычислительных методов анализа спутниковых данных в настоящее время все чаще успешно применяются нейросетевые подходы с использованием моделей сверточных нейронных сетей с глубоким обучением (DCNN, deep convolutional neural networks). Можно даже сказать, что анализ гиперспектральных спутниковых данных методами DCNN является важной новой подобластью применения нейросетевых подходов.

Глубокие сверточные нейронные сети – многослойные иерархически организованные каскады сетей прямого распространения, настраиваемые на накопленных больших базах данных. В случае удачно построенной модели DCNN и наличия должной базы данных нейросетевые методы

демонстрируют высокую точность решения задач обработки многопиксельных изображений высокого разрешения. Поэтому DCNN-подходы стали активно использоваться в задачах обработки гиперспектральных спутниковых изображений.

Помимо вполне удовлетворительного решения конкретных задач обработки изображений DCNN-подходы обладают рядом дополнительных достоинств. К ним можно отнести:

- Возможность «извлечения» важной дополнительной информации об изображении – иерархической совокупности глобальных характеристик изображения, так называемых признаков (high level hierarchical abstract features), полученных в результате надлежащей пространственной фильтрации изображения и отражающих скрытые взаимосвязи и корреляции.
- Нейросетевой способ сжатия данных (без потерь), осуществляемый глубокими сетями-автоэнкодерами.
- Возможность «автоматического» способа обработки больших изображений высокого разрешения.

К трудностям DCNN-подхода следует отнести:

- Огромное число настраиваемых параметров глубоких сетей, приводящее к очень большим временам предварительной настройки.
- Нехватку баз данных для настройки DCNN, приводящую к необходимости разработки методов построения дополнительных (синтезированных) баз данных.

Кроме нейросетевых подходов, основанных на построении сложных DCNN-сетей, в задачах гиперспектрального дистанционного зондирования давно используются также подходы, связанные с привлечением моделей распределенного (децентрализованного) искусственного интеллекта – биологически мотивированных моделей много-агентных систем (multi-agent systems, MAS). Этот класс параллельных адаптивных алгоритмов позволяет исследовать роль процессов коммуникации, кооперации, координации и самоорганизации в интеллектуальных вычислениях. Примеры успешного применения DCNN-сетей и MAS-методов в задачах анализа гиперспектральных изображений приведены в трех последних разделах доклада.

Традиционные вычислительные методы анализа гиперспектральных спутниковых изображений

В традиционных подходах используются в основном три группы методов атмосферной коррекции: эмпирические методы, методы моделирования процессов переноса излучения и гибридные методы. Приведем несколько примеров использования традиционных методов.

В работе [1] на основе применения теории переноса излучения к связанной системе атмосфера–земная поверхность был развит метод атмо-

сферной коррекции гиперспектральных изображений и дана оценка оптических характеристик атмосферы и отражающих характеристик земной поверхности. Был предложен также алгоритм восстановления оптической толщины аэрозольного слоя в видимом и ближнем инфра-красном (ИК) диапазонах спектра.

Алгоритм восстановления аэрозоля (над сложной земной поверхностью) высокой точности разрешения был предложен в работе [2]. При этом привлекались предварительно рассчитанные таблицы (так называемые LUT-таблицы) для нескольких моделей аэрозоля. Была также использована параметрическая формула для коэффициента отражения от верхней границы атмосферы.

В работе [3] было изучено влияние свойств листовой структуры лесных деревьев на отражательные характеристики лесных покровов Земли. На основе решения прямых и обратных задач переноса излучения в системе атмосфера–земная поверхность, а также решения задачи многократного рассеяния излучения внутри листа была установлена прямая корреляция между отражательными свойствами листвы и содержанием в листьях азота и углерода. Это позволяет получить дополнительную информации о земном углеродном цикле, оказывающем влияние на климатические изменения. Были проанализированы данные зондирования земных лесных покровов для 224 спектральных интервалов.

В работе [4] решалась задача восстановления оптических параметров атмосферы и коэффициента ламбертова поверхностного отражения от земной поверхности. Использовались расчеты методом Монте-Карло. Алгоритм позволил восстановить коэффициент отражения с высокой точностью (0.984–0.999).

В работе [5] был развит метод атмосферной коррекции гиперспектральных изображений на основе использования стандартного уравнения переноса излучения в нелинейной форме. Это позволило произвести восстановление отражательных характеристик элементов земной поверхности с высокой точностью путем решения оптимизационной задачи методом градиентного спуска.

В работе [6] на основе метода DOAS (Differential Optical Absorption Spectroscopy) был развит явный эффективный алгоритм коррекции влияния поглощения света атмосферными газами на поведение спектральных кривых гиперспектрального изображения. Алгоритм состоит в получении корректирующего множителя, на который домножается некорректированный коэффициент яркости. Оценки нужных решений уравнения переноса излучения были получены на основе привлечения принципов максимума и минимума для уравнения переноса со спектральной зависимостью. Результатом коррекции является коэффициент яркости для атмосферы, из

которой удалён поглощающий газ. Максимальная погрешность восстановления характеристик атмосферных газов не превышает 1%.

Решение задач обработки гиперспектральных спутниковых изображений с применением глубоких сверточных сетей

Сверточные нейронные сети (CNN) относятся к нейронным сетям третьего поколения. Они были инициированы после появления биологически мотивированной модели нейронной сети “Neocognitron”, созданной К. Фукушимой в 1980 г. [7] для задач трансляционно-инвариантной обработки изображений. После добавления принципов глубокого обучения (предложенного в 2006 г., [8, 9]) сети CNN приобрели большую популярность и стали широко использоваться для решения задач обработки изображений высокого разрешения.

Глубокие CNN-сети (DCNN) представляет собой многоступенчатые каскады сетей прямого распространения. Обычно это несколько сверточных слоев, слоев объединения, или подвыборки (так называемого пулинга, pooling), и слоев полносвязных сетей прямого распространения с обучением (см. рис. 2, где показана схема известной сети AlexNet, созданной А. Крижевским [10]). После работы сети на выходе каждого слоя пулинга появляется карта признаков изображения, полученная применением совокупности операций фильтрации со скользящим окном, (построенных по аналогии с действием рецептивных полей в зрительной системе мозга), и операций нелинейного усреднения в пределах малой окрестности каждого пикселя изображения. Настройка сетей DCNN требует привлечения больших баз данных для формирования обучающих выборок.




Рис. 2. Схема глубокой сети AlexNet [10], содержащей 5 сверточных слоев

К настоящему времени разработано много типов архитектур DCNN для решения задач обработки гиперспектральных изображений. К числу глубоких сетей часто употребляемых архитектур относятся: обычные

многослойные сверточные сети; сети глубокого доверия (deep belief networks, DBN) [9]; глубокие машины Больцмана (deep Boltzmann machines, DBM) [12]; каскады сетей-автоэнкодеров (stacked autoencoders, SAE), применяемые для нейросетевого сжатия информации [11]; так называемые ограниченные машины Больцмана (restricted Boltzmann machines, RBM) [13].

Отметим некоторые примеры успешного применения DCNN-подходов в задачах сегментации и классификации гиперспектральных изображений.

Задачи сегментации гиперспектральных спутниковых изображений

В ряде работ была продемонстрирована высокая точность «работы» DCNN-методов при использовании моделей DCNN достаточно простой архитектуры. Такие модели оказались эффективными при выделении простых классов объектов (здания, дороги, водные массивы, поля злаковых, лесные массивы). Так, в работе [14] для решения задачи сегментации спутниковых изображений было построено два типа DCNN-моделей, содержащих 3 и 4 сверточных слоя и полносвязный выходной слой. Метод был испытан на цветных изображениях реальной области во Франции с разрешением в 1.5m. Требовалось выделить 5 классов объектов: здания, сеть дорог, лесные массивы, поля зерновых культур, водные бассейны. В качестве базы данных была использована база данных геофизических изображений (Very High spatial Resolution, VHR), содержащая 10 000 образцов для каждого класса. Численная реализация модели была выполнена с использованием GPU. Потребовалось 5000 эпох для настройки каждой из моделей сети (с затратой 52.5 и 6.1 часов для вычислений).

Задачи классификации гиперспектральных изображений

В работах [15, 16] решалась задача классификации смешанного растительного покрова. Анализируемым изображением было 610×340-пиксельное изображение, содержащее 115 спектральных интервалов. Обучающая выборка содержала 3100 примеров. Потребовалось 5000 эпох для предварительного обучения сети и 50 000 эпох для окончательного обучения.

Метод классификации, основанный на использовании многослойных сетей-автоэнкодеров (SAE), содержащих 4–6 скрытых слоев, развитый в работе [17], продемонстрировал более точную работу по сравнению с такими хорошо «работающими» алгоритмами классификации, как метод опорных векторов (SVM): была достигнута точность 98% (вместо 96.6% для SVM-метода).

В работе [18] был построен ряд DCNN-моделей и выбрана модель оптимальной архитектуры, дающая наилучшие результаты классификации: 3 сверточных слоя, 1 слой пулинга и 2 полносвязных слоя. Использован Adam-алгоритм оптимизации, а также реализован так называемый метод

DropOut (разреживания связей полносвязного выходного слоя DCNN-сети). Развитый подход обеспечил точность классификации 85.31% (один из результатов классификации, полученных в [18], показан на рис. 3).

Высокая точность решения задач сегментации и классификации гиперспектральных изображений DCNN-методами получена в большой серии других работ (см, например, [19]).



Рис. 3. Пример классификации спутникового изображения DCNN-методом [18]: а) исходное изображение; б) результат классификации (выделенные классы объектов: здания, дороги и фон)

Использование много-агентных систем в задачах анализа гиперспектральных изображений

MAS-подход основан на моделировании открытых распределенных систем автономных взаимодействующих процессоров (агентов), способных кооперировать свои действия для совместной работы над решением общей задачи. Биологически инспирированные MAS-системы совместно синтезируют адекватную модель внешней среды и процесс кооперативной адаптации в ней. Кроме того, модели MAS потенциально предназначены для решения глобальных оптимизационных задач. Поэтому на основе моделей MAS удалось развить гибкие алгоритмы сегментации и классификации больших гиперспектральных изображений.

Для задач обработки гиперспектральных изображений были развиты MAS-методы, включающие операции с пространственно неоднородными пикселями. Так, в работе [20] была построена модель много-агентной системы, содержащая три типа агентов (*feature detection*, *subpixel mapping* and *decision agents*). Это позволило развить алгоритм классификации, оперирующий с пикселями изображения, содержащими смешанную информацию. Алгоритм продемонстрировал более точное выделение границ

классов в задаче классификации по сравнению со стандартным нейросетевым методом, примененным в той же задаче.

При анализе гиперспектральных изображений весьма информативной является заложенная в них спектральная информация, и поэтому важной является задача восстановления спектрального состава изображения (spectral unmixing problem). В работе [21] гибкий адаптивный алгоритм восстановления спектральных характеристик изображения был построен на основе MAS-модели пчелиного роя.

Заключительные замечания

В докладе приведены примеры работ, где продемонстрировано успешное применение DCNN-подходов и моделей MAS в задачах обработки гиперспектральных спутниковых изображений.

Список литературы

1. Basani C., Cavalli R.M., and Pignatti S. Aerosol Optical Retrieval and Surface Reflectance from Airborne Remote Sensing Data over Land // Sensors (Basel), 2010, N 10(7). P. 6421–6438.
2. Lyapustin A., Wang Y., Laszlo L., Kahn R., Korkin R., Remer L., Levy R., and Reid J.S. Multiangle implementation of atmospheric correction (MAIAC): 2. Aerosol algorithm // Journal of Geophys. Research. 2011. V. 116. D03211.
3. Knyazikhin Y., Schull M.A., Stenberg P., Mörtus M., Rautiainen M., Yang Y., Marshak A., Carmona P.L., Kaufmann R.K., Lewis P., Disney M.I., Vanderbilt V., Davis A.B., Baret F., Jacquemoud S., Lyapustin A., and Myneni R.B.. Hyperspectral remote sensing of foliar nitrogen content // Proc. of National Academy of Sciences. 2013. V. 110. E185–E192.
4. Тарасенков М.В., Белов И.И. Комплекс программ восстановления отражательных свойств земной поверхности в видимом и УФ-диапазонах // Оптика атм. и океана. 2014. Т. 27, № 7.
5. Денисова А.Ю., Мясников В.В. Атмосферная коррекция гиперспектральных изображений с использованием малого объема верифицированных данных // Компьютерная оптика. 2016. Т. 40, № 4, С. 526–534.
6. Николаева О.В. Алгоритм коррекции влияния поглощения света в атмосферных газах на гиперспектральные данные дистанционного зондирования // Компьютерная оптика, 2018. Т 42, №2.
7. Fukushima K. Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position // Biol. Cybern. 1980, V. 36, N. 4. P. 193–202.
8. Hinton G., Osindero S., The Y. The. A fast learning algorithm for deep belief nets // Neural Computation, 2006. V. 18, N 7. P. 1527–1554.
9. Hinton G., and Salakhutdinov R. Reducing the dimensionality of data with neural networks // Science, 2006. V. 313. N 5786. P. 504–507.

10. Krizhevsky A., Sutskever I., and Hinton G. Imagenet classification with deep convolutional neural networks // *Advances in Neural Information Processing Systems (NIPS)*, Lake Tahoe, NV, USA, 3–8 December 2012. P. 1097–1105.
11. Bengio Y., Lamblin P., Popovici D., and Larochelle H. Greedy layer-wise training of deep networks // *Proc. Neural Inf. Process. Systems*, Cambridge, MA, USA, 2007. P. 153–160.
12. Salakhutdinov R., and Hinton G. Deep Boltzmann machines // *Proc. Int. Conf. Artif. Intell. Statist.*, Clearwater Beach, FL, USA, 2009. P. 448–455.
13. Hinton G. et al. Apractical guide to training restricted Boltzmann machines // *Dept. Comput. Sci. Univ. Toronto, Toronto ON, Canada Tech. Rep. UTML*, 2010. TR2010-003.
14. Postadjian T, Le Brisa F., Sahbib H., Malletta C.. Investigating the potential of deep neural networks for large-scale classification of very high resolution satellite images // *Remote Sensing and Spatial Information Sciences*, 2017. V. IV-1/W1. P. 183–190.
15. Chen Y., Lin Z, Zhao X., Wang G., and Gu Y. Deep learning-based classification of hyperspectral data // *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2014, V. 7, № 6. P. 2094–2107.
16. Chen Y., Zhao X., and Jia X. Spectra-spatial classification of hyperspectral data based on deep belief network // *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2015, V. 8, № 6, P. 2381–2392.
17. Vincent P., Larochelle H., Lajoie H.I., Bengio Y., and Manzagol P. Stacked denoising autoencoders: Learning useful representations in a deep network with a local denoising criterion // *Journal of Machine Learning Research*, 2010. V. 11. P. 3371–3408.
18. Друки А.А., Спицын В.Г., Болотова Ю.А., Башлыков А.А. Семантическая сегментация данных дистанционного зондирования Земли при помощи нейросетевых алгоритмов // *Известия Томского политехнического университета. Инжиниринг георесурсов*. 2018. Т. 329, № 1. С. 59–68.
19. Басс Л.П., Кузьмина М.Г., Николаева О.В.. Сверточные нейронные сети с глубоким обучением в задачах обработки гиперспектральных спутниковых данных // *Препринт ИПМ РАН*. 2018. № 282, Москва.
20. Xu X., Zhong Y., and Zhang L. Adaptive Subpixel Mapping Based on a Multiagent System for Remote-Sensing Imagery // *IEEE Transactions on Geoscience and Remote Sensing*. 2014. V. 52, № 2.
21. Plaza A., Du Q., Bioucas-Dias J., Jia X., and F. A. Kruse F.A. Guest Editors. Special Issue on Spectral Unmixing of Remotely Sensed Data // *IEEE Transactions on Geoscience and Remote Sensing*, 2011. V. 49, N 11.

А. В. АГЕЕВ¹, В. С. СМОЛИН², С. М. СОКОЛОВ²¹Московский государственный технический университет им. Н.Э. Баумана²Институт прикладной математики имени М.В. Келдыша, Москва

alekseu147147@yandex.ru

ИССЛЕДОВАНИЕ ПРИМЕНИМОСТИ НЕЙРОННОЙ СЕТИ ДЛЯ УПРАВЛЕНИЯ СФЕРИЧЕСКИМ ПРИВОДОМ

Рассматривается задача о применении нейросети в качестве алгоритма управления сферическим приводом прямого управления. В процессе исследования была построена математическая модель сферического привода, на основе которой были выполнены численные эксперименты по поиску оптимальной структуры нейросети. Под оптимальностью понимается обеспечение как можно более точного позиционирования устройства, а также возможность реализации на ограниченных вычислительных ресурсах микроконтроллера, осуществляющего управление.

Ключевые слова: нейронная сеть, математическая модель, автоматическое управление.

Введение

В ряде задач автоматического управления одной из проблем является неточность сведений о состоянии объекта управления (ОУ). Причины таких неточностей могут быть разные, общей частью рассматриваемой проблемы является объективная сложность учёта и математического описания всех факторов, определяющих состояние ОУ. Прогресс в разработках сетей глубокого обучения, наметившийся в последнее время делает целесообразным исследование возможностей применения нейросетевого аппарата в составе систем управления технических устройств, при управлении которыми возникает указанная проблема. *Одним из преимуществ, которые дает использование нейросетевых алгоритмов, – это их предсказательная сила, благодаря которой негативное влияние неидеальности системы обратной связи возможно уменьшить.* В качестве целей нашего исследования можно указать получение ответов на два вопроса: можно ли построить нейросетевую структуру, позволяющую управлять устройством с проблемой неточных данных о состоянии объекта управления, и второй: если да, то можно ли оптимизировать эту структуру применительно к условиям конкретной задачи?

Для исследования была выбрана система управления таким интересным и перспективным мехатронным устройством, как сферический привод прямого управления (СППУ).

Экспериментальное выявление свойств закона управления

Вместо построения закона управления на основе описания свойств управляемого объекта (которое затруднено проблемой неточных данных) предлагается экспериментально выявлять законы соответствия между различными управляющими воздействиями и изменениями состояний объекта. Если объект характеризуется вектором измеряемых параметров x и управляющее воздействие u приводит к изменению x на векторную величину Δx , то, подавая в различных состояниях x случайные управляющие воздействия u , можно получить экспериментальное описание зависимости

$$u = f(x, \Delta x) \quad (1)$$

большим массивом соответствий $\{x_i, u_i, \Delta x_i\}$.

Данный массив соответствий может быть использован для обучения нейросети аппроксимации преобразования (1). После обучения нейросетевая аппроксимация позволит получать значения управляющего воздействия не только в проверенных точках $\{x_i, \Delta x_i\}$, но и в произвольных точках $\{x, \Delta x\}$ из области их существования.

Такой подход позволяет учесть плохо поддающиеся непосредственному измерению свойства и строить закон управления без построения математической модели управляемого объекта. Подход выглядит универсальным, но применимость его ограничена объектами и управляющими воздействиями, описываемыми небольшим числом параметров.

Выбранный объект управления – СППУ – как раз удовлетворяет этим условиям: хотя физическую модель СППУ нельзя назвать очень простой, состояние СППУ описывается двумя углами и их производными, а управляющее воздействие – двумя параметрами.

Предсказательная сила нейросети

Другим преимуществом нейросетевого подхода к построению закона управления на основе экспериментальных данных является устранение отрицательного влияния задержки в контуре обратной связи при штатном протекании процесса управления.


По состоянию объекта x и задаче изменения состояния Δx нейросеть строит аппроксимацию управляющего воздействия u (1). При штатном протекании процесса управления поставленная задача изменения состояния Δx достигается без влияния задержки в контуре обратной связи. Конечно, процесс выполнения задачи необходимо контролировать, и данные контроля могут быть получены только с некоторой задержкой τ . Но сравнение соответствия этих данных происходит с аппроксимированными по

также полученным с аналогичной задержкой данным о штатном течении процесса при обучении на массиве соответствий $\{x_i, y_i, \Delta x_i\}$.


Конечно, полностью устранить влияние задержки обратной связи нельзя. Если контроль протекания процесса управления выявляет его отклонения от штатного, то выбор нового закона управления, компенсирующего выявленные отклонения, будет проходить с задержкой. Но возможность управления без задержки, на основе предсказания результатов, хотя бы только при штатном режиме работы системы, позволяет строить более эффективные законы управления.

Постановка задачи

Темой данной работы является исследование применения нейронной сети в задаче управления СППУ. Данное устройство состоит из постоянного магнита, подвешенного в кардановом подвесе, двух пар соленоидов, окружающих карданный подвес, микроконтроллера ATmega128, силовых ключей и 4 датчиков Холла, которые установлены позади всей конструкции изображенной на рис 1.



(а)



(б)

Рис. 1. Общий вид сферического привода прямого управления (а) и схема (б)

Датчики Холла установлены на плоскости касательной к полусфере, описываемой задним торцом магнита в кардановом подвесе. На основе показаний этих датчиков определяется положение магнита и закрепленного на его переднем торце целеуказателя (отклонение по горизонтальной оси Ox и вертикальной Oz). Позиционирование выполняется генерацией ШИМа с напряжением 12 вольт, подающееся на катушки, посредством которых создается импульсное магнитное поле. Данное магнитное поле воздействует на магнит, закреплённый в центре вращения карданного подвеса, создает момент силы, который вращает всю систему.

При взаимодействии с устройством возможны два типа управления – позиционное (1) и траекторное (2):

1. Позиционирования устройства в точке за минимальный промежуток времени и его удержания в этой точке.

2. В течение заданного времени, как можно более точно, описывать рабочим органом определенную траекторию движения (окружность заданного радиуса, отрезок прямой).

СУ, устанавливающая скважность ШИМа, работает на основе ПИ-регулятора:

$$Ux_t = k_p Err + \tilde{U}x_t; \tilde{U}x_t = Ux_{t-1} + k_i Err; \quad (1)$$

$$Uz_t = k_p Err + \tilde{U}z_t; \tilde{U}z_t = Uz_{t-1} + k_i Err; \quad (2)$$

где Ux_t , Uz_t – значение скважности ШИМ в дискретных кодах $[0, 255]$. Err – текущая ошибка исполнения.

В СУ, построенной по указанной схеме, имеется проблема, которая заключается в том, что СУ не может с желаемой точностью зафиксировать рабочий орган в заданном положении. В результате этого целеуказатель дрожит, что в свою очередь снижает эффективность решения основной задачи управления СППУ с целеуказателем – обеспечения структурированного подсвета в составе регистрирующего модуля СТЗ. Предлагается исследовать возможность замены существующей СУ нейросетевой структурой.

Математическая модель СППУ

Основной задачей математической модели, является моделирование магнитного поля, с помощью которого осуществляется воздействие на постоянный магнит. Магнитное поле моделируется при помощи закона Био–Савара–Лапласа:

$$B(\vec{R}) = \frac{\mu_0}{4\pi} \int_{\gamma} \frac{I[d\vec{l} \times (\vec{R} - \vec{r})]}{|\vec{R} - \vec{r}|^3}, \quad (3)$$

где μ_0 – магнитная постоянная; I – ток, текущий по контур γ ; $\vec{R}$ – вектор, указывающий на точку, в которой выполняется вычисление магнитного поля; $d\vec{l}$ – вектор, направленный по течению тока, элемента интегрирования контура γ ; $\vec{r}$ – вектор, указывающий на элемент интегрирования $d\vec{l}$.

Для описания переходных процессов в соленоидах используются результаты измерений, проведенные в работе [1], на основе которых составляется уравнение переходных процессов в электрической цепи:

$$L \frac{dI}{dt} + RI = e, \quad (4)$$

где L – коэффициент самоиндукции; I – сила тока; R – сопротивление 2 катушек; e – напряжение.

В результате взаимодействия постоянного магнита с окружающей системой возникает вращательное движение, которое описывается вторым законом Ньютона:

$$I_{\omega} \vec{\omega} = \vec{M}, \quad (5)$$

где $\vec{\omega}$ – угловое ускорение; I_{ω} – момент инерции системы; $\vec{M}$ – суммарный момент всех сил, действующих в моделируемой системе.

Для вычисления момента инерции используется формула

$$I_{\omega} = \int r^2 dm. \quad (6)$$

Суммарный момент всех сил состоит из момента сил Ампера ($\vec{M}_B$). Данные силы стремятся ориентировать полюса постоянного магнита, по силовым линиям магнитного поля. Момент силы трения ($\vec{M}_{mp}$) и момента силы тяжести ($\vec{M}_{грав}$), возникающего из-за разбалансированности системы.

В итоге формула (5) преобразуется:

$$I_{\omega} \vec{\omega} = \vec{M}_B + \vec{M}_{разб} + \vec{M}_{mp}, \quad (7)$$

где $\vec{M}_B = [\vec{P} \times \vec{B}]$; $\vec{M}_{грав} = (0 \ 0 \ k \cos \beta)$; $\vec{M}_{mp} = -k_1 \vec{v} + k_2 \vec{v}$,

где $\vec{B}$ – магнитная индукция, вычисляемая по закону (3); $\vec{P} = w_0 i V_c \vec{n}$ – магнитный момент постоянного магнита (магнит моделируется? как и соленоиды в виде множества круговых витков с током. w_0 – число витков на единицу длины магнита; V_c – объем магнита; i – «сила тока» магнита; $\vec{n}$ – нормальный вектор магнита). Момент силы тяжести описывается в виде параметра k , поскольку не известно, как сильно разбалансирована система. Момент силы трения описывается в виде квадратичного полинома от скорости. Таким образом получается система (8), в которой C с индексами – это некоторые константы – начальные условия. f – некоторая функция, задающая управление напряжением на катушках, вследствие которой выполняется управление положением (углами поворота) лазерной указки.

$$\left\{ \begin{array}{l} I_{\omega} \vec{\omega} = \vec{M}_B + \vec{M}_{\text{разб}} + \vec{M}_{\text{тр}}, \\ \vec{M}_B = [\vec{P} \times \vec{B}], \\ \vec{P} = w_0 i V_c \vec{n}, \\ B(\vec{R}) = \frac{\mu_0}{4\pi} \int \frac{I[d\vec{l} \times (\vec{R} - \vec{r})]}{|\vec{R} - \vec{r}|^3}, \quad \vec{v}(0) = \vec{C}_{v_x v_z}, \\ \vec{N}(0) = \vec{C}_{xz}, \\ L \frac{dI}{dt} + RI = e, \quad I(0) = \vec{C}_{I_x I_z}, \\ e = f(*). \\ \vec{M}_{\text{тр}} = -k_1 \vec{v} + k_2 \vec{v}, \\ \vec{v} = \int \vec{\omega} dt, \\ \vec{N} = \int \vec{v} dt, \end{array} \right. \quad (8)$$

Применение нейронной сети

При построении модели нейронной сети важным этапом является определение ее структуры. Для этого были выполнены эксперименты по поиску оптимальной структуры сети на основе компьютерной модели СППУ.

Нейронная сеть – это алгоритм аппроксимации обучающих данных, который будет иметь следующий вид:

$$\vec{U} = ANN_D(\alpha_0, \beta_0, V_{\alpha_0}, V_{\beta_0}, \alpha^d, \beta^d, V_{\alpha^d}, V_{\beta^d}, n, m, \Theta), \quad (9)$$

где $\vec{U} = (U_x, U_z)$ – управляющее воздействие; α_0, β_0 – текущее положение СППУ (углы отклонения по оси Ox и Oz); $V_{\alpha_0}, V_{\beta_0}$ – текущая скорость СППУ; α^d, β^d – позиция, в которую требуется привести СППУ; $V_{\alpha^d}, V_{\beta^d}$ – скорость, которую должен иметь СППУ в конечной точке; n – число слоев в нейронной сети; m – число нейронов в каждом скрытом слое; Θ – веса связей нейронной сети, которые будут настраиваться во время обучения. Для настройки параметров сети используется функция ошибок – средне-квадратичная ошибка:

$$L(\vec{X}^l, a) = \frac{1}{l} \sum_{i=1}^l (\vec{y}_i - a(\vec{x}_i, \Theta)). \quad (10)$$

$\vec{X}^l$ – обучающая выборка, содержит: $\vec{x}_i$ – входы для алгоритма
 $a = ANN_D, \vec{y}_i$ – правильные ответы, соответствующие входам $\vec{x}_i$, l – раз-

мер обучающей выборки, θ – параметры модели, которые требуется настроить.

Алгоритм обучения заключается в минимизации функции ошибок по параметрам алгоритма:

$$\mu(\vec{X}^i, a) = \arg \min_{\theta} L(\vec{X}^i, a), \quad (11)$$

где μ – градиентный метод оптимизации, самый простой из которых – стохастический градиентный спуск.

На рис. 2 показаны графики результата управления моделями 1 и 3 (см. ниже табл. 1). Начальное положение СППУ – 0 радиан.




Рис. 2. Результат управления 2 моделей нейронной сети по оси Ох. a – положение устройства после управления. a^d – задание, на какой угол повернуть устройство. Конечная скорость после управления должна быть 0. Adam_nn5_nl32_relu – оптимизатор Adam, 5 слоев, 32 нейрона в каждом скрытом слое. Функция активации скрытых слоев ReLU

Оптимальная структура нейронной сети должна как можно более точно управлять (выбирается та модель, которая имеет минимальную ошибку при обучении), а также иметь как можно меньше нейронов. Таким образом, задачу поиска оптимальной структуры сети можно определить следующим образом:

$$S(\vec{X}^i, \vec{\mu}^b, a) = \min \{ \arg \min_{n,m} \mu_i(\vec{X}^i, a) \}, \quad (12)$$

где b – число алгоритмов, которые участвовали в отборе, используемые при настройке нейронной сети; n, m – размеры нейронной сети, которые принимают фиксированные дискретные значения.

Во время обучения нейронной сети возникла проблема – собираемых данных посредством математической модели СППУ оказалось недостаточно, для того чтобы нейронная сеть адекватно управляла моделью СППУ. Увеличить объем выборки представляется сложной задачей, так как вычисление обучающих данных на компьютерной модели СППУ занимает длительное время. Поэтому было решено сделать нейронную сеть, которая будет решать более простую задачу, чем изначальная, – это позиционирование СППУ по одной оси. Тогда модель нейронной сети будет выглядеть следующим образом:

$$U_{Ox} = ANN_{Ox}(\alpha_0, \alpha^d, n, m, \Theta); \quad (13)$$

$$U_{Oz} = ANN_{Oz}(\beta_0, \beta^d, n, m, \Theta); \quad (14)$$

где ANN_{Ox} – нейронная сеть управляющая только по оси Ox , при условии, что по оси Oz рабочий орган зафиксирован в нулевом положении. ANN_{Oz} – аналогично, но управление выполняется по другой оси. Стоит отметить, что существует зависимость управления по одной оси от положения по другой. Таким образом, управлять по двум осям моделями (13), (14) одновременно не получится. При построении моделей нейронной сети брались разные функции активации в скрытых слоях, а на выходном слое всегда использовалась линейная функция активации.

При поиске оптимальной структуры был выполнен перебор различных моделей нейронной сети и функций нелинейной активации. Лучшие модели по результатам отбора показаны в таблице 1. Все модели, представленные в таблице 1, на скрытых слоях имеют функцию активации:

$$relu(x) = \max(x; 0), \quad (15)$$

которая показала наилучшие результаты при решении данной задачи управления.

На основании табл. 1 можно утверждать, что модель 3 является оптимальной. Поскольку из представленных моделей она имеет меньше всего настраиваемых параметров – меньше вычислений во время применения, и входит в топ трех лучших моделей.

Заключение

На универсальном компьютере были построены ряд моделей нейросетей для управления СППУ. Эти нейросети исследовались на возможность построения эффективного управления математической моделью СППУ, построенной на том же компьютере.

Нейросетевая структура может быть реализована по такой схеме: одна часть – обучение и формирование весовых коэффициентов – на универсальном компьютере верхнего уровня управления, и вторая часть – исполнительная – на микроконтроллере АТМega338.

Таблица 1

Топ 10 лучших структур нейронной сети

Номер	Количество слоев	Количество нейронов в каждом скрытом слое	Средняя абсолютная ошибка длительности управляющего сигнала. Секунды
1	5	256	0.000224
2	4	256	0.000230
3	5	32	0.000239
4	5	128	0.000240
5	4	128	0.000244
6	4	64	0.000253
7	8	64	0.000254
8	8	32	0.000261
9	7	32	0.000263
10	6	64	0.000269

Исследования показали, что возможно использовать нейросетевые структуры в задачах автоматического управления, но для реализации на микроконтроллере, необходимо продолжить исследования, так как нейросети для достаточно точного управления необходим большой набор обучающих данных, что является серьезным препятствием для решения сложных задач.

Авторы выражают благодарность В.С. Ярошевскому и А.А. Богуславскому за помощь в изучении реального образца СППУ, обсуждение и полезные замечания.

Список литературы

1. Соколов С.М., Трифонов О.В., Ярошевский В.С. Система управления сферическим приводом прямого управления с датчиками Холла в контуре обратной связи // Препринт ИПМ им. М.В. Келдыша. 2008. № 94. 20 с.
2. Воронцов К.В. Курс лекций. Машинное обучение [Электронный ресурс] Режим доступа: <http://www.machinelearning.ru/wiki/index.php?title=Mo>. Дата последнего обращения 11.05.19.
3. Николенко С., Кадури А., Архангельская Е. Глубокое обучение. Санкт-Петербург: Питер. 2018. 480 с.
4. Тамм И.Е. Основы теории электричества: учебное пособие для вузов. Москва: Физматлит, 2003. 616 с.

Е. С. СОКОЛОВА¹, А. А. ТЕЛЬНЫХ²

¹Нижегородский научно-исследовательский институт радиотехники

²Институт прикладной физики РАН, Нижний Новгород

Pogoda2014groza@gmail.com, telnykha@yahoo.com

КЛАСТЕРИЗАЦИЯ И ИДЕНТИФИКАЦИЯ ГРОВОВЫХ КОНВЕКТИВНЫХ ЯЧЕЕК В МЕЗОМАСШТАБНЫХ СИСТЕМАХ

Рассматривается задача кластеризации и идентификации грозовых конвективных ячеек в мезомасштабных системах по их геометрическим признакам. Кластеризация грозовых конвективных ячеек проводится по метеорадиолокационной отражаемости. Предлагается оригинальный метод идентификации грозовых конвективных ячеек, результатом которого является построение функции риска грозы. Весовые коэффициенты функции риска находятся с использованием алгоритмов машинного обучения.

Ключевые слова: опасные погодные явления, грозовые конвективные ячейки, прогнозирование гроз.

Введение

Опасные погодные явления: ураганный ветер, град, смерч, ливневые осадки, гроза и т.д., наносят ощутимый ущерб различным отраслям экономики по всему миру и приводят к многочисленным человеческим жертвам. Грозовые явления стоят на втором месте по степени опасности среди опасных погодных явлений. В частности, они приводят к многочисленным человеческим жертвам по всему земному шару каждый год.

Опасные погодные явления образуются комплексно в мезомасштабных системах. Мезомасштабные системы образуются из совокупности конвективных ячеек (КЯ). Оценка параметров мезомасштабных систем проводится по метеорадиолокационным данным. Конвективные ячейки на экране метеорадиолокатора идентифицируются как области с высокими значениями отражаемости, что соответствует высоким значениям влажности в атмосфере. Для прогнозирования опасных метеоявлений используют алгоритмы, заложенные в сверхкраткосрочном прогнозе (nowcasting). Впервые данный термин был введен 1970-х годах Браунингом [1, 3]. Метеорологические службы многих стран создают собственные алгоритмы прогнозирования гроз в рамках систем сверхкраткосрочного прогноза в зависимости от имеющегося инструментария и географических особенностей. Для прогнозирования гроз используют дополнительно данные из сети грозопеленгаторов и спутников [4, 5, 6, 7] или составляют мезомасштабный анализ на региональном уровне, используя аэрологические дан-

ные о состоянии атмосферы [8, 9]. Но не всегда есть возможность использовать дополнительную информацию для прогнозирования грозовых явлений. Задача состоит в создании автоматического алгоритма прогнозирования гроз с использованием радиолокационных данных (отражаемости).

Постановка задачи

Мезомасштабная система – это динамическая система, состоящая из множества конвективных ячеек. Каждая КЯ имеет собственные жизненные циклы и размеры. В течение своего жизненного цикла КЯ взаимодействует с другими, сливаясь в более крупные КЯ или напротив бесследно исчезая. Как правило, жизненный цикл КЯ составляет от 30 мин до двух часов, что обуславливается внешними условиями образования мезомасштабной системы. Каждая КЯ является динамической системой меньшего масштаба. Внешние условия в атмосфере и внутренние условия внутри каждой КЯ обуславливают возникновение или отсутствие града, грозы или ливневых осадков и т.д. По метеорологическим данным можно спрогнозировать град или оценить количество осадков в КЯ в заданной области, но спрогнозировать грозу в заданной области не удастся [1, 2].

В работе рассматривается задача кластеризации и идентификации грозовых конвективных ячеек в мезомасштабных системах. Кластеризация грозовых конвективных ячеек проводится по изображениям метеорадиолокационной отражаемости. Идентификация грозовых конвективных ячеек проводится с помощью функции риска, аргументами которой являются геометрические признаки.

Описание алгоритма

Из метеорадиолокационных данных мы получили метеорадиолокационное изображение отражаемости (МРИ). По данным грозопеленгаторов мы построили карту грозовых разрядов на поверхности Земли. МРИ и карта грозовых разрядов накладывались друг на друга по синхронизованному временному интервалу. Затем мы интегрировали полученные изображения по высоте. На полученном радиолокационном интегрированном изображении (РИИ) мы проводили кластеризацию КЯ по заданному порогу отражаемости. На РИИ рассчитывались геометрические особенности КЯ: координаты центра масс, площадь, периметр, значения большой и малой полуосей, описанного вокруг КЯ эллипса. Эти же геометрические особенности рассчитывались для совокупности КЯ.

На карту грозовых разрядов была нанесена сетка разбиения на квадраты. Проводился расчет расстояния от центра каждого квадрата до центра масс ближайшей к нему КЯ. Также проводился расчет расстояния от центра каждого квадрата до центра масс совокупности КЯ. На рис. 1 показана схема расчета расстояний. Расстояние r – расстояние от точки B до точки C (от центра квадрата до центра масс ближайшей КЯ). Расстояние R –

расстояние от точки B до точки O (от центра квадрата до центра масс совокупности КЯ).




Рис. 1. Схема расчета расстояний R и r

Мы проводили расчет геометрических признаков для ближайшей КЯ и получили вектор признаков (1).

$$\vec{V}_1 = [v_1, \dots, v_n], \quad (1)$$

где v – геометрический признак, $n = 8$ – общее количество признаков.

Мы проводили расчет геометрических признаков для совокупности КЯ:

$$\vec{V}_2 = [u_1, \dots, u_m], \quad (2)$$

где u – геометрический признак, $m = 6$ – общее количество признаков совокупности КЯ.

В общем виде вектор признаков $\vec{V}$ является функцией геометрических особенностей как для одной КЯ, так и совокупности КЯ (3).

$$\vec{V}(\vec{V}_1, \vec{V}_2) = \vec{V}(x, y, s, p, mi, ma, \theta, X, Y, S, P, MI, MA, \vartheta, \frac{1}{r}, \frac{1}{R}, \frac{1}{rR}), \quad (3)$$

где x, y – координаты центра масс КЯ, s – площадь КЯ, p – периметр КЯ, mi, ma – большая и малая полуоси описанного эллипса КЯ, θ – угол наклона mi , r – расстояние от центра квадрата (см. рис. 1) до центра масс КЯ, X, Y – координаты центра масс совокупности КЯ, S – площадь совокупности КЯ, P – периметр совокупности КЯ, MI, MA – большая и малая полуоси описанного эллипса совокупности КЯ, ϑ – угол наклона MA , R – расстояние от центра квадрата (см. рис. 1) до центра масс совокупности КЯ. Мы построили функцию риска:

$$R = R(\vec{V}_1, \vec{V}_2), \quad (4)$$

где V_1 – вектор признаков до ближайшей ячейки, V_2 – вектор признаков со всей структуры, n – число признаков, m – общее число ячеек разбиения

на карте грозовых разрядов. Функция риска принимает значения либо 0, либо 1. Значение 0 соответствует отсутствию риска появления грозового разряда, значение 1 соответствует максимальному риску появления грозы.

Точный вид функции риска зависит от алгоритма машинного обучения.

К нашей задаче мы применили логистическую регрессию и метод опорных векторов. Оба алгоритма подходят для нашей бинарной задачи с небольшим набором признаков [10].

Функция риска для логистической регрессии имеет вид

$$R(z) = \frac{1}{1 + e^{-z}}, \quad (5)$$

$$Z = w_0 + w_1 v_1 + \dots + w_m v_m, \quad (6)$$

где $v_1, \dots, v_m$ – геометрические признаки, m – общее количество геометрических признаков, $w_0, w_1, \dots, w_m$ – искомые коэффициенты в уравнении (5) [12].

Функции риска для метода опорных векторов с полиномиальным ядром в степени 2 имеет вид

$$R(V, V') = (\langle V, V' \rangle + \text{const})^2, \quad (7)$$

где V – пространство признаков, V' – новое признаковое пространство. Задача сводится к нахождению уравнения разделяющей плоскости [10].

Эксперимент и результаты

В рамках проведенной работы было разработано программное обеспечение, которое включало в себя распаковку и обработку метеорадиолокационной отражаемости и построение МРИ по высотным срезам и карты грозовых разрядов на поверхности Земли.

Для эксперимента мы использовали радиолокационные данные и данные с грозопеленгаторов (lightning strike) с сайта национального центра климатических данных США [11] за несколько летних дней. В нашей работе мы использовали данные с нескольких доплеровских радаров серии SWD-88, находящихся друг от друга на небольшом удалении, так чтобы они имели зоны перекрытия. Метеорадары находятся в населенных пунктах Bismark, Minot, Aberdeen. Данные по грозам мы брали из Lightning Strikes. Мы создали собственную базу данных грозовых разрядов. Общее количество грозовых событий в базе было 8350 событий за 6 дней, которые были спроецированы на 300 МРИ. Мы исключали изображения, на которых не было КЯ. Каждое изображение разбивалось на фрагменты размером 16, 32 и 64 пиксела (пкс), что соответствовало размеру области на земной поверхности 4, 8 и 16 км соответственно. На выходе с каждого изображения получали таблицу признаков. Размер таблицы признаков определялся разбиением карты грозовых разрядов. Например, при разбиении карты 64 на 64 размер таблицы признаков был 14 на 8000. Получен-

ные результаты были разделены на обучающую и тестовую выборки, в процентном соотношении 70 на 30.

МРИ и карты грозových разрядов были синхронизированы по времени. В среднем временной интервал между кадрами МРИ составлял 5 мин. Время наблюдения составляло от 2-х до 3-х часов. На рис. 2 приведен пример инвертированного МРИ, совмещенного с картой грозových разрядов. Радиус наблюдения составляет 150 км. На МРИ наложена карта грозových разрядов. Грозовые разряды отмечены квадратиками. На приведенном примере можно увидеть, что гроззовые разряды локализуются в областях с большими значениями водности.




Рис. 2. Инвертированное МРИ, совмещенное с картой грозových разрядов

На рис. 3 представлено инвертированное РИИ с кластеризованными КЯ по уровню не менее 45 dBZ. Кластеризованные КЯ выделяются эллипсами. Программно производится расчет геометрических особенностей КЯ в пикселах. В одном пкс содержится 250 метров.



Рис. 3. Инвертированное радиолокационное интегрированное изображение КЯ

Значения вектора признаков были масштабированы, и все значения лежали в интервале от 0 до 1. Размер матрицы признаков по вертикали зависел от шага разбиения сетки на карте грозových разрядов. Мы проводили раз-

биение с шагом 16, 32, 64 пкс. Обучение проводили с использованием программного обеспечения WEKA.

Мы составляли вектор признаков априорно, основываясь на физической интуиции. Мы попытались визуально оценить корректность подбора признаков грозовых конвективных ячеек. На рис. 4 и рис. 5 приведен пример диаграммы рассеяния признаков.




Рис.4. Диаграмма рассеяния между 5 и 13 признаками




Рис. 5. Диаграмма рассеяния между 1 и 10 признаками

Из визуализации диаграмм рассеяния признаков 1 и 10 видно, что они коррелированы между собой, в то время как признаки 5 и 13 не коррелированы. Мы использовали метод PCA для получения набора декоррелированных признаков. Критерий отбора признаков заключался в сохранении максимальной информации при сокращении элементов вектора признаков. В результате проведенных расчетов у нас осталось 8 признаков из 14. Разный шаг разбиения карты грозовых разрядов не повлиял на результат исключения признаков методом PCA. Полученный методом PCA вектор

признаков, мы отправили на обучение в WEKA, используя классификатор логистической регрессии. В табл. 1 приведены результаты ошибок обучения.

Таблица 1

Сравнение результатов обучения классификатора логистическая регрессия с разным шагом разбиения

Шаг разбиения/ ошибка	Kappa statistic	RAE (%)	RRSE (%)	MAE	Время построения модели (с)
16	0,52	62	73	0,15	7,4
32	0,52	62	73	0,17	2,6
64	0,51	62	79	0,17	0,31

Из таблицы 1 следует, что шаг разбиения карты грозových разрядов на 16 и 32 пкс не влияет на результат обучения. При шаге 16 пкс требуется большее время для решения задачи более чем в 3 раза. При шаге 64 пкс результаты обучения чуть хуже, но время, затраченное на выполнение задачи, на порядок меньше при меньшем шаге разбиения.

Не измененный вектор признаков мы отправили на обучение, используя классификатор метод опорных векторов. Ядро было выбрано полиномиальное в степени 2. В таблице 2 представлены результаты вычислений.

Таблица 2

Сравнение результатов обучения классификатора метод опорных векторов с разным шагом разбиения

	Kappa statistic	RAE (%)	RRSE (%)	MAE	Время построения модели (с)
16	0,49	52	98	0,35	750
32	0,54	46	96	0,2	121
64	0,56	45	94	0,19	4,01

В таблице 2 представлены результаты обучения. Наилучшие результаты обучения достигаются при шаге разбиения 64 пкс.

При сравнении ошибок, полученных при обучении двух классификаторов, выигрывает классификатор логистической регрессии по всем значениям ошибок.

Затем мы экзаменовали полученные модели на тестовых данных при шаге разбиения 64 пкс. В таблице 3 приведены результаты вычислений.

Таблица 3

Сравнение результатов “экзамена” классификаторов логистическая регрессия и метода опорных векторов

	Kappa statistic	MAE
logistic	0,51	0,17
SMO	0,31	0,45

В таблице 3 представлены результаты экзамена моделей, построенных на классификаторах логистической регрессии и метод опорных векторов. Логистическая регрессия для данной задачи подходит, т.к. MAE меньше в 2 раза, а Kappa Statistic на 0,2 больше. Из модели обучения классификатором логистической регрессии были найдены веса функции риска.

Результаты наших исследований получились достаточно скромные, вследствие того, что мы использовали малое количество грозовых событий. Помимо этого, мы использовали только геометрические признаки грозовых ячеек, не используя пространственное распределение КЯ по высоте и текстурные признаки.

Выводы

Предложен и реализован оригинальный метод кластеризации и идентификации грозовых конвективных ячеек по метеорадиолокационной отражаемости.

Сравнение результатов обучения показало, что в предложенной задаче классификатор логистической регрессии показывает лучшие результаты, чем метод опорных векторов. Весовые коэффициенты функции риска находили, используя методы машинного обучения.

Программа дальнейших исследований будет включать в себя расширение базы данных и числа информативных признаков грозовых конвективных ячеек, построение алгоритма прогнозирования гроз по временной последовательности МРИ.

Список литературы

1. Матвеев Л.Т. Физика атмосферы. Санкт-Петербург : Гидрометеоиздат, 2000. 780 с.
2. Шметтер С.М. Физика конвективных облаков. Санкт-Петербург : Гидрометеоиздат, 1972. 288 с.
3. Базлова Т.А. Метеорологические автоматизированные радиолокационные сети. Санкт-Петербург: Гидрометеоиздат, 2002. 202 с.
4. Bally J. The thunderstorm Interactive Forecast System: Turning Automated Thun-

- derstorm Tracs into Sever // Weather and Forecasting. 2004. 19. P. 64–72.
5. Qui T., Zhang S., Zhou H., Bai X., Liu P. Application Study of Machine Learning in Lightning Forecasting // Information Technology Journal. 2013. V. 12, N 21. P. 6031–6037.
6. Emamghoreishi S.A., Moini R., Sadeghi S.H.H. A modular neural network approach for locating cloud-to-ground lightning strokes // IEEE. 2001. P. 412–421.
7. Bala K., Choubey D.K., Paul S. Soft Computing and Data mining Techniques for Thunderstorms and Lightning Prediction: A Survey // International Conference on Electronics, Communication and Aerospace Technology. 2017. P. 42–46.
8. Chatterjee D., Chakrabarty Dr. H. Application of Machine Learning Technique to Predict Severe Thunderstorms using upper air data // International Journal of Scientific & Engineering Research. 2015. Vol. 6. № 7. P. 1527–1530.
9. Калинин Н.А., Ветров А.Л., Смирнова А.А. Мезомасштабный анализ и сверхкраткосрочный прогноз // Ученые записки Казанского университета. 2009. Т. 151, № 4. С. 209–216.
10. Rusmusin C.E., Williams K.I. Gaussian Processes for Machine Learning, the MIT Press. 2006. P. 247.
11. <http://www.ncdc.noaa.gov/nexradiinv/choosesite.jsp>
12. Флах П. Машинное обучение. Наука и искусства построения алгоритмов, которые извлекают знания из данных. Москва : ДМК Пресс. 2015. 387 с.

Т. К. БЕРГАЛИЕВ¹, М. Е. МАЗУРОВ²

¹Московский физико-технический институт

²Российский экономический университет имени Г. В. Плеханова, Москва
timurbergaliyev@gmail.com, mazurov37@mail.ru

ОБ ЭФФЕКТИВНОСТИ ГОСУДАРСТВЕННОЙ ПОДДЕРЖКИ В ОБЛАСТИ РАЗРАБОТКИ И ВНЕДРЕНИЯ НЕЙРООБРАЗОВАТЕЛЬНЫХ ТЕХНОЛОГИЙ*

Одним из успешных примеров современной школьной цифровой лаборатории в области нейротехнологий является отечественная разработка – нейроконструктор компании ООО «Битроникс». Исследованы результаты внедрения нейроконструктора. Построено линейное регрессионное уравнение, характеризующее зависимость вовлеченных школьников в работу по изучению нейротехнологий от показателей: количество выделенных бюджетных средств, количество проведенных мероприятий по ознакомлению с нейротехнологиями.

Ключевые слова: цифровая лаборатория, нейроконструктор, нейротехнологии, школьники младших классов, регрессионная зависимость.

Введение

В настоящее время одной из самых быстрорастущих отраслей цифрового мира в Российской Федерации и в мире является область нейротехнологий, включающая в себя создание человеко-машинных интерфейсов, современные средства реабилитации, новые подходы к конструированию робототехнической и медицинской техники, современные средства расширения возможностей человека и протезирования, носимую электронику, средства дистанционного мониторинга состояния человека, нейроразвлечения и киберспорт, анализ данных на базе нейросетевых технологий и многое другое.

В основе отрасли нейротехнологий лежат междисциплинарные знания в области физиологии человека, биологии, физики, проектирования человеко-машинных интерфейсов, технологии анализа данных, инженерно-технические навыки отладки и тестирования сложных систем.

В целях знакомства и обучения (подготовки школьников и студентов) по указанным областям знаний должны быть выработаны оптимальные образовательные инструменты и подходы, которые органично встроены в

* Работа поддержана договором на проведение НИОКР с Фондом поддержки проектов Национальной технологической инициативы от 16 мая 2017 г. № 7/17 гр.

существующую структуру образования (интегрируемые в основную и дополнительную образовательные программы, апробированные в различных школах).

Успешным примером современной школьной цифровой лаборатории в области биофизики и нейротехнологий является отечественная разработка компании ООО «Битроникс» совместно с лабораторией прикладных кибернетических систем МФТИ. Цифровая лаборатория BiTronics Lab иллюстрируется на рис. 1.



Рис. 1. Цифровая лаборатория BiTronics Lab для введения в нейротехнологии школьников

По состоянию на текущий момент цифровые лаборатории успешно используются в средних школах и частных образовательных центрах в 20 регионах России, в частности, во Всероссийском образовательном центре «Сириус», в ряде технопарков «Кванториум» и т.д.

На базе цифровой лаборатории в области нейротехнологий в течение трех лет проводится профиль «Нейротехнологии» Олимпиады Национальной технологической инициативы. Компания является активным участником рынка Нейронет, членом отраслевого союза Нейронет, компания входит в список лидерских проектов, поддерживаемых Агентством стратегических инициатив (АСИ).

Данная работа выполняется в рамках реализации инновационных проектов по разработке и освоению новых видов наукоемкой продукции в целях реализации дорожных карт НТИ «Нейронет» по направлению развития нейротехнологий, одобренных Президиумом Совета при Президенте России по модернизации экономики и инновационному развитию России. Место данной разработки лежит в Дорожной карте в секторе Нейро-

Второе поколение нейрообразовательных систем должно содержать основные сведения о стандартных нейронных сетях и созданных в последнее время избирательных нейронных сетях, давать понятие о глубоком обучении нейронных сетей. Предполагается, что данная нейрообразовательная система будет доступна для школьников старших классов, студентов высших учебных заведений и специалистов смежных профессий.

Рассматриваемое направление исследований включает нейрообразовательные технологии, предназначенные для обучения широкого круга школьников, студентов и специалистов смежных профессий. Иллюстрация этого круга людей показана на photographиях рис. 3.

В этой статье моделирование эффективности государственной поддержки в области разработки и внедрения нейрообразовательных технологий приводится как один из способов решения проблем, возникающих в реальном мире.



Кружок старших школьников

Семинар студентов

Воркшоп специалистов смежных профессий

Рис. 3. Круг потребителей нейротехнологий: школьники, студенты, специалисты смежных профессий

Методы моделирования в социальных системах

В данной работе исследованы результаты внедрения нейротехнологий в социальной среде – школьников старших классов. Общая схема модели-

рования иллюстрируется на рис. 4.




Рис. 4. Общая схема моделирования

На рис. 4 снизу показано реальное развитие процессов в сложной системе, на рис. 4 сверху показано развитие процессов в математической модели системы. Исследование процессов в математической модели позволяет установить процессы в реальной системе без её фактической реализации.

В настоящее время одним из способов моделирования процессов в социальных системах является метод агентного моделирования [1, 2]. Структурная схема агентного моделирования приведена на рис. 5.



Рис. 5. Структурная схема агентного моделирования

Моделирование применяется в случае, если эксперименты с реальными объектами/системами или их прототипирование невозможно или слишком дорого. Моделирование позволяет оптимизировать систему до

её реализации. Моделирование включает в себя отображение проблемы из реального мира в мир моделей (процесс абстракции), анализ и оптимизацию модели, нахождение решения и отображение решения обратно в реальный мир. Мы различаем аналитическое и имитационное моделирование.

Результаты работ по популяризации и внедрению образовательных нейротехнологий среди школьников младших классов приведены в таблице 1.

Таблица 1

Результаты внедрения нейрообразовательных технологий в школах

Показатель\год	2016	2017	2018	2019
Кол-во тематических мероприятий, шт.	25	50	100	120
Кол-во выделенных бюджетных средств млн руб.	10	20	30	40
Кол-во вовлеченных школьников, человек	2000	4500	8000	10000
Кол-во поданных заявок на патенты, шт.	0	2	3	
Количество вовлеченных педагогов, человек	5	15	40	50

Значения количества мероприятий, количества вовлеченных школьников, количества вовлеченных преподавателей за 2019 год указаны из анализа предшествующих временных рядов по этим показателям. Построено линейное регрессионное уравнение, характеризующее зависимость вовлеченных школьников в работу по изучению нейротехнологий y от показателей: количество выделенных бюджетных средств x_1 , количество проведенных мероприятий по ознакомлению с нейротехнологиями x_2 . Линейная регрессионная зависимость была получена в виде

$$y = a_0 + a_1x_1 + a_2x_2,$$

где a_0, a_1, a_2 – параметры, $a_0 = -273.8$, $a_1 = 115.5$, $a_2 = 47.6$. Полученная регрессионная зависимость показана на рис. 6.

Найденное регрессионное уравнение показывает, что количество школьников, вовлеченных в изучение нейротехнологий, пропорционально использованным государственным средствам, количеству мероприятий, проведенных для популяризации и вовлечения школьников в изучение нейротехнологий.




Рис. 6. Регрессионная зависимость. Зависимость вовлеченных школьников в работу по изучению нейротехнологий от показателей: количество выделенных бюджетных средств, количество проведенных мероприятий по ознакомлению с нейротехнологиями

Заключение

Одним из примеров современной школьной цифровой лаборатории в области биофизики и нейротехнологий является отечественная разработка – цифровая лаборатория компании ООО «Битроникс» совместно с лабораторией прикладных кибернетических систем МФТИ. Указан круг потребителей нейротехнологий: школьники, студенты и специалисты смежных профессий. Исследованы результаты внедрения нейротехнологий в социальной среде – школьников младших классов. Построено линейное регрессионное уравнение, характеризующее зависимость вовлеченных школьников в работу по изучению нейротехнологий от показателей: количество выделенных бюджетных средств, количество проведенных мероприятий по ознакомлению с нейротехнологиями.

Список литературы

1. Макаров В.Л., Бахтизин А.Р. Социальное моделирование – новый компьютерный прорыв (агент-ориентированные модели). Москва : Экономика. 2013. 295 с.
2. Мазуров М.Е. Идентификация математических моделей нелинейных динамических систем. Москва: URSS. 2018. 383 с.

И. Г. ШЕЛОМЕНЦЕВА

Красноярский государственный медицинский университет
им. проф. В.Ф. Войно-Ясенецкого

Сибирский федеральный университет, г. Красноярск
inga.shell@yandex.ru

**ПРИМЕНЕНИЕ СИСТЕМЫ НЕЙРО-НЕЧЕТКОЙ
КЛАССИФИКАЦИИ NEFCCLASS ДЛЯ РАСПОЗНАВАНИЯ
ИЗОБРАЖЕНИЙ АНАЛИЗОВ МОКРОТЫ, ОКРАШЕННОЙ
ПО МЕТОДУ ЦИЛЯ-НИЛЬСЕНА**

Рассматривается задача построения нейро-нечеткой системы классификации медицинских изображений на примере анализов мокроты, окрашенных по методу Циля-Нильсена при помощи модели NEFClass. Для решения задачи классификации были определены оптимальные параметры использования программы NEFClass-PC на базе вектора признаков цвета и формы.

Ключевые слова: метод Циля-Нильсена, нейро-нечеткие сети, NEFClass, среднеквадратичная ошибка, точность классификации.

Введение

В настоящее время в медицине и биоинформатике широко используются разнообразные модели и алгоритмы систем искусственного интеллекта – нейронные сети, дискриминантный анализ, логистическая регрессия и т.д. – для задач прогнозирования, классификации, построения систем поддержки принятия врачебных решений. К сожалению, эти системы имеют мало возможностей для работы с неточными, неопределенными и неполными данными. Кроме того, зачастую существующих знаний о предметной области недостаточно для построения интеллектуальной системы вследствие трудностей формализации и разных подходов в экспертных оценках. В таких случаях более применимы становятся нейро-нечеткие системы, которые позволяют найти необходимый баланс между точностью и интерпретируемостью [1].

Целью текущего исследования является изучение применимости использования системы нейро-нечеткой классификации на примере системы NEFClass к изображениям анализов мокроты, содержащих микобактерии туберкулеза.

Модели и методы

В качестве материалов исследования выступают изображения анализов мокроты пациентов противотуберкулезного диспансера, окраска которых производилась по методу Циля–Нильсена (рис. 1).




Рис 1. Пример изображений анализов мокроты, окрашенной по методу Циля–Нильсена

Предварительная предобработка изображения анализов мокроты включала в себя такие операции, как операцию фильтрации для повышения резкости изображения и избавления от шума, операцию сегментации с целью выделения ROI (регионов интереса), операцию выделения признаков из сегментов изображения [2].

Построение вектора признаков ROI текущего исследования было основано на атрибутах цвета (минимальные, средние, максимальные значения параметров RGB и HSV) и атрибутах формы (площадь ROI, размеры по вертикали и горизонтали). В результате исследования информативности признаков и корреляционного анализа для вычислительного эксперимента был выбран вектор признаков, состоящий из двух параметров формы ROI (площади и ширины) и 6 параметров цвета (средние значения красного, зеленого и синего цветов, максимального значения синего цвета модели RGB и средних значений цветового оттенка и яркости модели HSV) [3].

Система NEFClass (NEuro Fuzzy CLASSication) была разработана Detlef Nauck и Rudolf Kruse для задач распознавания образов – определения правильного класса или категории для входного вектора. В терминах системы входной вектор представляется как $x = (x_1, x_2, \dots, x_n) \in \mathbb{R}^n$ и класс C_j является подмножеством $\mathbb{R}^n$. База правил системы аппроксимирует неизвестную функцию φ , задача которой отобразить входной вектор x в класс C_j (1) [4]:

$$\varphi: \mathbb{R}^n \rightarrow \{0,1\}^b, \varphi(x) = (c_1, c_2, \dots, c_b), \text{ with } c_j = \begin{cases} 1, & \text{если } x \in C_j, \\ 0, & \text{иначе.} \end{cases} \quad (1)$$

NEFClass реализует нечеткие правила вида (2):

$$\text{IF}(x_1 \text{ is } A_{1r}) \text{AND} \dots \text{AND} (x_n \text{ is } A_{nr}) \text{THEN class } C_{jr}, \quad (2)$$

где r – номер правила ($r = 1, 2, \dots, R$);

A_{ir} ($i = 1, 2, \dots, n$) – нечеткие множества, представляющие лингвистические описания признаков в r -м правиле;

C_{jr} ($j \in \{1, 2, \dots, b\}$) – метка класса в r -м правиле.

Обобщенная структура системы NEFClass с n входами и R правилами представлена на рисунке 2 [5]. Архитектура строится на базе трех слоев: слой L1, задача которого – обеспечить ввод вектора признаков и определить степень их принадлежности к множествам A_{ir} , слой L2, задача которого выполнить нечеткую классификацию на основе R правил, с использованием операторов AND и t -norm, и слой L3, задача которого в нахождении взвешенной суммы выходов L2.




Рис 2. Структура модели NEFClass

Модель NEFClass может быть построена как на основе частичных знаний о предметной области, так и может выполнить моделирование базы правил в автоматическом режиме. Полученная система прозрачна и может быть легко интерпретирована исследователем. Использование системы NEFClass предполагает выполнение следующих этапов [6]:

1. Задание начальных значений входного вектора. Для подготовки данных используется файл с расширением `dat`, созданный в текстовом редакторе. Сам файл представляет собой строочное описание элементов входного вектора и выходных значений, разделенных пробелами или знаками табуляции. Входные значения должны быть веще-

- ственными или целыми значениями, а классы должны быть закодированы как двоичные векторы.
2. Создание или генерация базы правил. Генерация базы правил проходит в автоматическом режиме, в дальнейшем можно выполнить редактирование правил нейро-нечеткой сети.
 3. Обучение нечеткого множества – алгоритм системы осуществляет перебор значений обучающей выборки до тех пор, пока не выполнится критерий останова. Можно настроить три разных критерия: максимальное значение ошибки; определенное значение ошибки; количество эпох, при которых ошибка обучения не уменьшается.
 4. Тестирование обученной модели.

Вычислительный эксперимент

Вычислительный эксперимент строился на основе программы NEFClass-PC, которая является свободно распространяемым программным обеспечением. Первичные параметры работы этой системы представлены в таблице 1.

Программа NEFClass-PC содержит инструменты для автоматического построения базы правил, пример которой представлен в таблице 2. Программа предоставляет возможность указывать только количество термов для каждой переменной, а не конкретизировать диапазоны при помощи числовых значений, что является ограничением для гибкости нейронечеткой сети [7].

Согласно основному принципу моделирования, в процессе вычислительного эксперимента в исходном наборе параметров обучения менялось по одному критерию. Выборочные результаты процесса обучения нейронечеткой сети при помощи программы NEFClass-PC представлены в таблицах 3–5. В качестве параметра сравнения результатов вычислительного эксперимента использовались значения среднеквадратичного отклонения (RMSE) и точности ассигасы, выраженной в проценте правильной классификации по обоим классам (Acc, %)

Таблица 1

Значение параметров для работы программы NEFClass-PC

<i>Параметр</i>	<i>Значение</i>
Алгоритм обучения	Классический
Функция агрегации	Взвешенная сумма
Максимальное количество эпох	500
Ассиметричное обучение	Да
Критерий останова	Количество эпох, при которых ошибка обучения не уменьшается = 100

Таблица 2

Пример правил, генерируемых системой NEFClass

Правило	V1	V2	V3	V4	V5	V6	V7	V8	Результат (класс)
	Площадь	Ширина	Avg R	Avg G	Avg B	Max B	Avg H	Avg V	
R1	small	large	large	large	large	large	large	large	2
R2	small	large	small	large	small	small	medium	large	2
R3	small	large	small	large	small	small	large	large	2
R4	small	large	large	large	large	small	large	large	1
R5	small	large	large	large	small	small	large	large	2
R6	small	large	small	large	large	large	large	large	1

Рассмотрим зависимость качества обучения от количества правил (таблица 4). В качестве базы для эксперимента возьмем набор данных со следующими параметрами: алгоритм генерации правил – лучшее для класса, режим работы с соседями – перекрытие, количество термов – индивидуально. Исследование будем проводить на тестирующей выборке.

Таблица 3

Пример правил, генерируемых системой NEFClass

Номер опыта	Асс, %	RMSE	Кол-во правил	Параметры	Кол-во термов
1	84,1	0,4224	30	Лучшее для класса	инд
2	84,36	0,4043	20	Лучшее для класса	инд
3	84,38	0,36066	15	Лучшее для класса	инд
4	84,29	0,3197	10	Лучшее для класса	инд
5	84,99	0,3540	15	Лучшее	инд
6	84,20	0,4027	20	Лучшее	инд
7	82,71	0,4016	25	Лучшее для класса	4
8	84,1	0,2395	10	Лучшее для класса Перекрытие соседей	2
9	84,07	0,2569	12	Лучшее для класса Перекрытие соседей	2
10	84,32	0,3047	15	Лучшее для класса Перекрытие соседей Сигма 0.02	3
11	84,3	0,2693	20	Лучшее для класса Перекрытие соседей Сигма 0.02	3

Выбор этих параметров является наилучшим для решения текущей задачи, так как выбранный режим генерации правил обеспечивает их опти-

мальный отбор, одновременно уменьшая проблему размерности, характерную для нейро-нечетких систем, выбранный режим работы с соседями обеспечит необходимую точность решения. При асимметричном обучении процесс построения базы правил более гибкий, что обеспечит наилучшую классификацию.

Анализируя таблицу 4, можно сделать вывод, что оптимальным количеством правил для выбранного вектора признаков, при сигме = 0,01, является диапазон от 7 до 15, вопреки стандартной закономерности, что чем больше правил, тем точнее результат обучения. Оптимальным количеством правил для выбранного вектора признаков, при сигме = 0,02, является диапазон от 20 до 25.

Таблица 4

Зависимость качества обучения от количества правил

Номер	Количество правил	RMSE	Асс, %	Сигма
1	15	0,2767	84,06	0,01
2	8	0,2385	84,07	0,01
3	9	0,2623	84,01	0,01
4	20	0,3496	83,72	0,01
5	17	0,2856	84,15	0,01
6	7	0,2397	84,11	0,01
7	4	0,2978	84,11	0,01
8	15	0,3047	84,31	0,02
9	20	0,2693	84,30	0,02
10	25	0,2705	84,95	0,02
11	30	0,3145	83,31	0,02

Рассмотрим зависимость качества обучения от количества термов (таблица 5). За основу возьмем исходный набор данных и количество правил, равное 8 для сигмы = 0,01 и 20–30 для сигмы = 0,02. Анализ таблицы 5 позволяет утверждать, что оптимальным количеством термов для текущей базы правил является 2 или 3.

Таблица 5

Зависимость качества обучения от количества термов

Номер	Количество термов	Количество правил	RMSE	Асс, %	Сигма
1	2	8	0,2348	83,96	0,01
2	3	8	0,2657	84,00	0,01
3	4	8	0,3300	84,11	0,01
4	5	8	0,3582	84,08	0,01
5	3	20	0,2693	84,30	0,02
6	3	25	0,2705	84,95	0,02
7	2	30	0,2501	84,56	0,02
8	2	25	0,2413	84,53	0,02

Выводы

Базовыми параметрами сравнения результатов обучения нечеткой нейронной сети при помощи системы NEFClass являются среднее квадратичное отклонение и точность классификации.

Программа NEFClass-PC чувствительна к размеру обрабатываемого файла и ограничена в построении базы правил с нуля, что можно отнести к недостаткам использования данной программы. Однако при использовании NEFClass-PC для построения и использования нейро-нечеткой модели можно отметить ее быстроедействие и производительность при построении базы правил.

Для конкретного набора данных всегда существует оптимальное количество правил и термов, влияющие на качество обучения сети, которое можно получить экспериментальным путем.

Минимальная среднее квадратичная ошибка, полученная при построении, равна 0,2348, что является хорошим результатом, а максимальное значение точности равно 84,99%, что можно отнести к среднему результату.

Оптимальный баланс критериев качества классификации для задачи распознавания изображений анализов мокроты, окрашенной по методу Циля–Нильсена на базе вектора признаков, построенного на параметрах цветовых моделей RGB и HSV, система нейро-нечеткой классификации NEFClass показала с использованием количества термов 2 или 3, количества правил, равным 8 для $\sigma = 0,01$ и количества правил равным 25 для $\sigma = 0,02$, а также режима работы с соседями с перекрытием.

Список литературы

1. Шеломенцева И.Г. Обзор моделей и средств реализации нечетких нейронных сетей в приложении к обработке медицинских изображений на примере изображения анализа мокроты // Синергия наук. 2017. № 17, Т.1. С. 681–687.
2. Наркевич А.Н., Шеломенцева И.Г., Виноградов К.А., Сысоев С.А. Сравнение методов сегментации цифровых микроскопических изображений мокроты, окрашенных по методу Циля–Нильсена // Инженерный вестник Дона. 2017. № 4. С. 1–11.
3. Наркевич А.Н., Плотников Д.В., Виноградов К.А., Катаева А.В. Сравнение методов отбора признаков для идентификации объектов на цифровых изображениях микроскопических препаратов. Инженерный вестник Дона. 2018. №2. С. 1–10.
4. Gliwa B., Byrski A. Hybrid neuro-fuzzy classifier based on NEFCLASS model // Computer Science. 2011. No 12. P. 115–135.
5. Gorzalczyk Marian B. Computational Intelligence Systems and Applications. Physica. 2002. 364 p.
6. <http://fuzzy.cs.ovgu.de/nefclass/>
7. Зайченко Ю.П., Дьяконова С.В. Применение нечеткого классификатора NEFClass к задаче распознавания зданий на спутниковых изображениях сверхвысокого разрешения // Вісник НТУУ «КПІ». Інформатика, управління та обчислювальна техніка: збірник наукових праць. 2011. № 54. С. 31–35.

В. В. ДЕРЯБИН

Государственный университет морского и речного флота
им. адмирала С.О. Макарова, г. Санкт-Петербург
gmavitder@mail.ru

**РАСЧЁТ ШИРОТЫ МЕСТА СУДНА НА ОСНОВЕ
НЕЙРОННОЙ СЕТИ**

Предложена модель счисления геодезической широты места судна на основе нейронной сети. Модель реализована в виде двухслойной нейронной сети прямого распространения, удовлетворяющей условиям универсальной аппроксимации. На вход сети поступают начальная широта, данные о курсе и скорости, а также информация о течениях. На выходе получается значение широты на конец промежутка интегрирования. Результаты тестирования позволяют говорить об удовлетворительной средней точности разработанной модели.

Ключевые слова: широта судна, счисление, нейронная сеть, численное интегрирование.

Введение

Задача определения широты места судна по информации, поступающей от навигационных датчиков (лаг, гирокомпас), возникает при ведении счисления пути судна в навигационном компьютере (системе). Точность её решения зависит от погрешностей исходных данных (в основном измерений), погрешностей округления чисел в навигационной ЭВМ, а также погрешностей метода.

Последний тип погрешностей возникает, в частности, при выборе алгоритма численного интегрирования. В настоящее время в алгоритмах счисления, как правило, для интегрирования используются методы прямоугольников [1–2] и трапеций [3–4]. Могут также использоваться и другие методы, основанные на использовании формул Ньютона–Котеса [5–6]. Выбор в пользу формул Ньютона–Котеса объясняется тем, что аналитический вид интегрируемой функции не известен, и её значения известны лишь, как правило, в дискретные равноотстоящие моменты времени.

Как хорошо известно [7], формулы Ньютона–Котеса основаны на предположении, что подынтегральная функция может быть заменена интерполяционным многочленом Лагранжа на промежутке интегрирования. В случае использования метода трапеций она принимается линейной; метода Симпсона – квадратичной и т.д. Такое предположение в определённой степени ограничивает точность формул. В связи с этим возникает необходимость разработки других алгоритмов численного интегрирова-

ния, не использующих предположений о характере поведения интегрируемой функции между узлами интегрирования.

В качестве таких алгоритмов могут выступать нейронные сети как системы, обладающей свойствами универсальной аппроксимации [8, 9]. Значение интеграла на промежутке времени интегрирования может быть представлено как функция многих переменных – величин, определяющих значения интегрируемой функции в её узлах. В соответствии со свойствами универсальной аппроксимации указанная функция нескольких переменных может быть представлена с любой наперёд заданной точностью нейронной сетью.

Постановка задачи

Уравнение счисления широты места судна φ может быть записано следующим образом:

$$\varphi(\tau) = \varphi(0) + \int_0^{\tau} \frac{V_N(t)}{M(\varphi)} dt, \quad (1)$$

где τ – промежуток времени t интегрирования; V_N – проекция вектора абсолютной (относительно грунта) скорости судна на направление меридиана; M – радиус кривизны меридиана.

Будем использовать метод трапеций для численного интегрирования (1). Выражение переписывается в следующем виде:

$$\varphi(\tau) \approx \varphi(0) + \frac{1}{M(0)} \cdot \frac{V_N(0) + V_N(\tau)}{2} \cdot \tau. \quad (2)$$

Знак $\approx$ в соотношении (2) возникает не только в результате перехода от подынтегральной функции к её значениям на концах отрезка $[0; \tau]$, но также и в результате предположения, что при малом τ $M(\tau) \approx M(0)$. Таким образом, в методе трапеций подынтегральная функция заменяется линейной. Как было упомянуто выше, в этом проявляется частный случай несовершенства формул Ньютона–Котеса.

С другой стороны, на основании метода трапеций можно заключить, что

$$\varphi(\tau) - \varphi(0) \approx f(\varphi(0), V_N(0), V_N(\tau)),$$

где f – некоторая непрерывная функция.

Северная составляющая абсолютной скорости судна определяется следующим соотношением:

$$V_N = V_x \cos K - V_y \sin K + V_T \cos K_T, \quad (3)$$

где V_x, V_y – соответственно продольная и поперечная составляющие относительной скорости судна; K – его истинный курс; V_T – скорость течения; K_T – направление течения.

В результате имеем следующую функциональную зависимость:

$$\varphi(\tau) - \varphi(0) \approx g(\varphi(0), K(0), K(\tau), V_x(0), V_x(\tau), V_y(0), V_y(\tau), V_T(0), V_T(\tau), K_T(0), K_T(\tau)), \quad (4)$$

где g – некоторая непрерывная функция.

Поставим теперь задачу смоделировать зависимость g на основе нейронной сети.

Алгоритм на основе нейронной сети

Будем использовать двухслойную нейронную сеть прямого распространения (FFNN – Feed-Forward Neural Network), выходной слой которой имеет один единственный нейрон с тождественной функцией активации, а входной (скрытый) слой – m нейронов с функциями активации, которые удовлетворяют свойствам универсальной аппроксимации. А именно: функции активации должны быть не полиномами и локально интегрируемыми (по Риману). Такое требование к функциям активации доказано в работе [9]. Общий вид нейронной сети представлен на рис. 1.

При практическом построении нейронной сети общая её архитектура должна иметь конкретную реализацию. В первую очередь это относится к выбору числа нейронов в скрытом слое. Несмотря на то что имеется ряд исследований [8, 10], посвящённых данному вопросу, все решения, предлагаемые в них, имеют привязку к свойствам функции, которая приближается нейронной сетью. В частности, в [10] оценка погрешности аппроксимации даётся на основе первого абсолютного момента распределения Фурье. Для оценки указанной величины необходимо проводить дополнительные исследования аппроксимируемой функции. Более того, число нейронов, на практике, сильно ограничивают вычислительные возможности компьютера, на котором выполняется обучение нейронной сети. Поэтому ограничимся таким чисто эмпирическим подходом: учитывая ограниченность вычислительных ресурсов и большое количество образцов, будем брать m максимальным, которое возможно для вычислений на используемом компьютере с заданным количеством образцов.

Второй вопрос касается функций активации. Несмотря на то что условия универсальной аппроксимации позволяют использовать очень широкий класс функций в качестве активационных, будем ограничиваться наиболее популярными и уже хорошо зарекомендовавшими себя решениями [8]. В частности, к таким решениям относятся логистическая функция и функция «гиперболический тангенс».




Рис. 1. Архитектура нейронной сети – общий вид (n – количество скалярных входных сигналов)

Вход/выход нейронной сети

Входной сигнал нейронной сети X определим в соответствии с выражением (4).

$$X = \begin{bmatrix} \varphi(0), \\ \left(\varphi(0), K(0), K(\tau), V_x(0), V_x(\tau), V_y(0), V_y(\tau), V_T(0), V_T(\tau), K_T(0), K_T(\tau) \right)^T \end{bmatrix}$$

Вход сети является составным. Первая его часть, $\varphi(0)$, подаётся сразу на второй (выходной) слой сети через постоянный весовой коэффициент, всегда равный +1. Вторая часть, векторная, подаётся на первый (скрытый) слой.

Выходным сигналом сети является геодезическая широта центра тяжести судна на поверхности общеземного эллипсоида, определяемая на конце промежутка интегрирования, $\varphi(\tau)$.

Таким образом, непосредственно аппроксимируется разность $\varphi(\tau) - \varphi(0)$ как функция векторной части входа X . Тем не менее нейросетевая реализация позволяет на выходе получать непосредственно широту $\varphi(\tau)$, а не приращение.

Реализация нейронной сети

Рассмотренная выше нейросетевая модель определения широты судна в режиме счисления была реализована в среде MATLAB R2018a. Количество нейронов скрытого слоя было выбрано равным 30. В качестве функции активации нейронов скрытого слоя был выбран гиперболический тангенс, очень широко применяемый в нейронных сетях, решающих задачи аппроксимации функций. Общий вид представлен на рис.2.




Рис. 2. Реализация нейронной сети в среде MATLAB

Обучение нейронной сети

Для обучения нейронной сети был подготовлен набор учебных данных, состоящий из двух подмножеств – набора обучающих и тестовых данных. На основе учебных образцов происходит коррекция коэффициентов нейронной сети. На основе тестовых образцов – контроль способности нейронной сети к обобщению в процессе обучения. Алгоритм формирования набора учебных данных выглядит таким образом:

1. Задаются границы возможных значений компонент вектора входного сигнала X . Для широты – $\{\min[\varphi(0)], \max[\varphi(0)]\}$; для курса – $\{\min[K(0)] = \min[K(\tau)], \max[K(0)] = \max[K(\tau)]\}$, для продольной скорости – $\{\min[V_x(0)] = \min[V_x(\tau)], \max[V_x(0)] = \max[V_x(\tau)]\}$; для поперечной скорости – $\{\min[V_y(0)] = \min[V_y(\tau)], \max[V_y(0)] = \max[V_y(\tau)]\}$; для модуля вектора скорости течения – $\{\min[V_T(0)] = \min[V_T(\tau)], \max[V_T(0)] = \max[V_T(\tau)]\}$; для направления вектора течения – $\{\min[K_T(0)] = \min[K_T(\tau)], \max[K_T(0)] = \max[K_T(\tau)]\}$.

2. Задаются шаги компонент вектора входного сигнала X . Для широты – $\Delta\varphi$; для курса – ΔK ; для скорости – $\Delta V_x, \Delta V_y$; для элементов течения – $\Delta V_T, \Delta K_T$.

3. На основе данных п. 1 и 2 формируются последовательности значений соответствующих компонент входного вектора X . Элементы последовательностей разделены шагом, границы являются терминальными точками последовательностей. Совокупность последовательностей образует набор входных обучающих данных. Затем для каждой последовательности (соответствующей компоненте X) находятся точки, которые являются средним арифметическим двух соседних элементов указанной последовательности. Упомянутые точки (будучи вычисленными для каждой составляющей X) и формируют набор входных тестовых данных.

4. На основе соотношений (2) и (3) вычисляются значения выходного сигнала сети для входных данных обучающего и тестового подмножеств.

5. Набор учебных данных сформирован.

В качестве алгоритма обучения используется метод Левенберга–Марквардта (Levenberg–Marquardt), очень распространённый метод обучения второго порядка для нейронных сетей рассматриваемого класса.

Результаты

Для формирования набора учебных данных использовались следующие значения параметров:

1. Границы.

$$\{\min[\varphi(0)] = 0, \max[\varphi(0)] = 90^\circ\},$$

$$\{\min[K] = 0, \max[K] = 360^\circ\},$$

$$\{\min[V_x] = -1, \max[V_x] = 20 \text{ уз.}\};$$

$$\{\min[V_y] = -5, \max[V_y] = 5 \text{ уз.}\};$$

$$\{\min[V_T] = 0, \max[V_T] = 5 \text{ уз.}\};$$

$$\{\min[K_T] = 0, \max[K_T] = 360^\circ\}.$$

1 уз. (узел) равен одной морской миле (1852 м) в час.

2. Дискретность (шаг).

$$\Delta\varphi = 3^\circ, \Delta K = 3^\circ, \Delta V_x = 1 \text{ уз.}, \Delta V_y = 2 \text{ уз.}, \Delta V_T = 1 \text{ уз.}, \Delta K_T = 15^\circ.$$

При формировании компонент вектора X используется допущение, что значения величин на концах интервала интегрирования $[0; \tau]$ равны между собой, т.е.

$$K(\tau) = K(0), V_x(\tau) = V_x(0), V_y(\tau) = V_y(0), V_T(\tau) = V_T(0), K_T(\tau) = K_T(0).$$

Такое допущение будет тем более справедливым, чем меньше будет величина τ .

Для алгоритма обучения (Левенберга–Марквардта) использовались следующие параметры:

– минимальное значение градиента: $1 \cdot 10^{-20}$;

– максимальное значение параметра алгоритма μ : $1 \cdot 10^{20}$;

- время обучения: 5 суток;
- наибольшее допустимое количество последовательных циклов, при которых значение функции стоимости не уменьшается (validation checks): 10.

Дискретность модели t была выбрана равной 1 с.

Для расчёта радиуса кривизны меридиана в формуле (2) использовались параметры общеземного эллипсоида WGS-84.

Вычисления выполнялись на компьютере с процессором Intel Core i7 4770 К и оперативной памятью 32 ГБ. В результате обучения было пройдено 713 эпох (циклов) пакетного режима. Наилучший результат был зафиксирован для последнего цикла: функция стоимости составляет $2,0046 \cdot 10^{-16}$ (для образцов из тестового подмножества). Таким образом, в данном случае обучения тестовая выборка не была использована по своему прямому назначению (установить факт ухудшения обобщающих свойств сети). Тем не менее её использование позволило зафиксировать факты ухудшения обобщающих свойств по мере обучения сети.

Для образцов из тестового подмножества также было определено наибольшее значение модуля ошибки прогнозируемой широты. Оно составило $3,8717 \cdot 10^{-4}$ угловых минут. Так как широта прогнозируется для правой границы промежутка интегрирования, и он равен 1 с, то в худшем случае, можно ожидать ошибку за 4 часа, равную 5,575' широты. В принципе, данное значение уже является характеристикой точности сети, т.к. при постоянном характере входного сигнала данное значение точно может быть достигнуто. Тем не менее интерес вызывает работа сети и в других точках, не совпадающих с точками из тестовой и обучающей выборок.

После обучения нейронная сеть была протестирована следующим образом:

1. Задаётся общее число тестовых ситуаций N , а также продолжительность плавания судна в каждой такой ситуации ΔT .

2. С использованием датчика случайных чисел равномерного распределения из промежутков возможных значений (см. п. 1 алгоритма формирования набора учебных данных) выбираются составляющие вектора X .

3. Вектор X подаётся на вход нейронной сети, которая рассчитывает широту φ_n . Все составляющие вектора, за исключением начальной широты, остаются постоянными в пределах модельной ситуации. Начальная широта берётся с предыдущего временного этапа прогноза.

4. На основе выражений (2) и (3) рассчитывается широта, принимаемая за эталонную φ_a^* .

5. Определяется наибольшее значение модуля ошибки широты на основе п. 3 и 4 $e_\varphi = \max_{[0; \Delta T]} (|\varphi_n - \varphi_a|)$.

6. Пункты 2–5 повторяются до тех пор, пока не будет рассмотрено заданное количество тестовых ситуаций.

*Примечание. В процессе тестирования отслеживается также, чтобы эталонная широта принимала значения только из Северного полушария, т.к. на этапе обучения было задано $\{\min[\varphi(0)] = 0, \max[\varphi(0)] = 90^\circ\}$.

Работа алгоритма тестирования с параметрами $N = 1000$, $\Delta T = 4$ ч приводит к результатам, представленным в таблице 1.

Таблица 1

Результаты тестирования нейронной сети ($N = 1000$)

Величина	$\max(e_\varphi)$ [1;N]	$\text{mean}(e_\varphi)$ [1;N]	$\min(e_\varphi)$ [1;N]
Значение	3,5957'	0,5541	$4,4199 \cdot 10^{-4}$
Описание	наибольшее из всех ситуаций	среднее по всем ситуациям	наименьшее из всех ситуаций

Как показали результаты тестирования, максимальная ошибка весьма значительна (3,5957' за 4 часа плавания). В среднем работу системы можно считать удовлетворительной (0,5541' за 4 часа плавания).

Заключение

В результате проведённого исследования разработан нейросетевой алгоритм определения широты места судна по информации, поступающей от навигационных датчиков (лаг, гироскоп), данных о скорости дрейфа и течения. Нейронная сеть выполняет функцию алгоритма счисления пути судна. Работа сети возможна при любых вариантах комплектации судна навигационными приборами (техническими средствами судовождения). Обучение сети выполнялось на основе метода трапеций. По отношению к указанному методу выполнялось и тестирование. Результаты тестирования позволяют говорить лишь об удовлетворительной средней точности счисления широты.

И алгоритм трапеций, и нейронная сеть используют одни и те же данные – значения величин, по которым рассчитывается интегрируемая функция на концах отрезка интегрирования. То есть сеть не использует какую-то дополнительную информацию, за счёт которой можно надеяться на повышение точности. Тем не менее метод трапеций исходит из предположения, что подынтегральная функция ведёт себя как линейная между узлами, а нейронная сеть работает без такого предположения. В этом состоит преимущество нейросетевого подхода, пусть пока лишь теоретическое.

Дальнейшие исследования могут быть направлены, в первую очередь,

на повышение точности разработанной нейросетевой системы. Уменьшение ошибки прогноза может быть достигнуто за счёт совершенствования алгоритмов формирования образцов, настройки (обучения) сети, а также путём поиска оптимального количества нейронов в скрытом слое. Возможно, ускорение в поиске оптимальной по точности структуре может быть достигнуто введением дополнительных скрытых слоёв, т.е. переходом к глубокой архитектуре.

Список литературы

1. Каврайский А.В. Алгоритмы точного решения прямой и обратной навигационных задач // Навигация и гидрография. 2002. № 14. С. 126–136.
2. Пантелеев Н.Ф., Кузнецов В.В., Глазков А.Г., Власова А.А. Счисление геодезических координат B , L , h для объектов, движущихся по поверхности Земли // Труды ФГУП НПЦАП. Системы и приборы управления. 2010. № 1. С. 69–72.
3. Волович А., Волович Г. Интегральные акселерометры // Компоненты и технологии. 2002. № 1. С. 66–72.
4. Челноков Ю.Н. Кватернионные и бикватернионные модели и методы механики твердого тела и их приложения. Геометрия и кинематика движения. Москва : Физматлит. 2006. 512 с.
5. Дерябин В.В. Кинематическая модель движения судна // Вестник государственного университета морского и речного флота имени адмирала С.О. Макарова. 2017. Т. 9, № 2. С. 260–271.
6. Hanawa D., Yonekura T., Kishi Y. An error analysis of polynomial form dead reckoning model based on a numerical analysis // AMO – Advanced Modeling and Optimization. 2005. Vol. 7, № 1. С. 85–98.
7. Березин И.С., Жидков Н.П. Методы вычислений. Том 1. Москва : ГИФМЛ. 1962. 464 с.
8. Хайкин С. Нейронные сети: Полный курс. Москва : ИД «Вильямс». 2006. 1103 с.
9. Hornik K. Some new results on neural network approximation // Neural Networks. 1993. Vol. 6 (8). P. 1069–1072.
10. Barron A.R. Universal approximation bounds for superpositions of a sigmoidal function // IEEE Transactions on information theory. 1993. Vol. 39 (3). P. 930–945.

С. В. АЛЕКСЕЕВ, А. Д. КОНЕВА, Я. А. СЕРЕДАНижегородский государственный университет им. Н.И. Лобачевского
sergey.alekseev@itlab.unn.ru

СЕГМЕНТАЦИЯ ЭКГ НЕЙРОННЫМИ СЕТЯМИ: ОШИБКИ И ИХ ИСПРАВЛЕНИЕ

Данная работа посвящена исследованию того, каким образом происходит исправление ошибок в ансамблях глубоких сверточных нейронных сетей на распространенной прикладной задаче: разметке электрокардиограмм (ЭКГ). Также была исследована возможность использования информации об ошибках ансамбля для оценки качества построенной сетью репрезентации данных.

Ключевые слова: сверточные нейронные сети, ансамбль, сегментация, ошибки, сердечный цикл.

Введение

Коррекция ошибок является одной из основных проблем современных нейронных сетей [1]. Эффект коррекции ошибок часто возникает в ансамблях нейронных сетей. Известно, что в большинстве случаев производительность ансамбля лучше, чем производительность отдельных сетей из него [2]. Тем не менее предсказание того, какие ошибки базовой модели исправит ансамбль, а какие нет, является сложной задачей.

Задача исправления возможных ошибок обученной модели является актуальной, поскольку внутреннее представление данных нейронной сетью достаточно трудно интерпретировать [3]. Надежность нейронной сети напрямую связана с качеством внутренней репрезентации, которую она строит. В контексте задачи медицинской диагностики, анализ качества репрезентации особенно важен в связи с тем, что некоторые патологии часто представлены лишь небольшим количеством образцов относительно общего объема данных [4].

Несбалансированность классов в данных часто приводит к тому, что метрики оценки качества дают неоправданно хороший результат. Но сбалансировать данные хорошо известными методами возможно не всегда, так как не всегда ясно, какие классы требуют баланса. В данной работе эта проблема иллюстрируется на примере сегментации ЭКГ: датасет не сбалансирован по заболеваниям. Заболевания оказывают разное влияние на морфологию компонент сердечного цикла, поэтому репрезентация данных сетью должна содержать информацию о том, как каждый сердечный цикл должен выглядеть при каждом заболевании из выборки. В дан-

ной работе исследуется то, как именно ансамбль исправляет ошибки одной сети, чтобы сделать вывод о качестве внутренней репрезентации сети.

Одним из способов проверить надёжность внутреннего представления данных является использование состязательных примеров [5]. Другой распространённый подход к анализу качества репрезентации основывается на визуализации изученных атрибутов разных уровней [6]. Для моделей с вниманием может быть использована визуализация внимания [7]. Новым направлением является поиск метрики для оценивания степени «распутывания» в репрезентации [8]. Другие методы можно найти в обзоре [3].

Набор данных

LUDB [9] – открытый набор данных, содержащий записи ЭКГ 200 пациентов. Каждая запись представлена 10-секундным сигналом, снятым с двенадцати отведений с частотой дискретизации 500 Гц. Для каждой записи есть разметка врача, отмечающая три сегмента сердечного цикла: P, QRS и T. Точное обнаружение этих комплексов важно для диагностики по ЭКГ.

Подготовка ЭКГ включает в себя удаление дрейфа изолинии, которое является первым шагом предобработки ЭКГ в большинстве приложений [10]. Дрейф изолинии – это низкочастотный артефакт на ЭКГ, который может быть вызван движением пациента или нарушением контакта электрода и кожи пациента [11] и не содержит нужной для диагностики информации. Для его устранения к ЭКГ применяются два медианных фильтра, как описано в [10].

Базовая нейронная сеть

Сверточные нейронные сети хорошо подходят для множества прикладных задач. В частности, они используются для обработки медицинских данных, включая анализ ЭКГ [12]. Таким образом, архитектурой для базовой нейронной сети ансамбля была выбрана сверточная.

Выход софтмакс слоя интерпретируется как вероятности того, что данная точка является частью T-волны, P-волны, QRS-комплексом или ничем из этого.

Итоговый результат является бинарной маской для каждого из всех трёх типов компонент сердечного цикла. Для каждого канала маска генерируется, основываясь на выходе софтмакс слоя: в каждый момент времени выбирается канал, имеющий наибольшее значение. Ему назначается 1, остальным каналам – 0. Примеры ЭКГ, соответствующего им результата софтмакс слоя и итоговой разметки приведены на рис. 1 и 2.

Обучение осуществлялась по всем 12 отведениям. Тем не менее уменьшение числа отведений ухудшает результат незначительно.




Рис. 1. Пример разметки ЭКГ одной сетью. На верхнем рисунке верхними прямоугольниками изображена врачебная разметка, нижними – сетью. Разные оттенки показывают разные комплексы. Нижний рисунок показывает необработанный выход софтмакс слоя




Рис. 2. Выходной сигнал сети в случае наличия патологий. На верхнем рисунке верхними прямоугольниками изображена врачебная разметка, нижними – сетью. Разные оттенки показывают разные комплексы. Нижний рисунок показывает необработанный выход софтмакс слоя

Оценка качества

В этой работе мы обозначаем каждый компонент сердечного цикла на

ЭКГ первой и последней его точками. Чтобы оценить качество разметки для каждого из типа точек (например, начало Р-волны), используется алгоритм, работающий следующим образом: для каждой точки данного типа на истинной разметке ищется соответствующая точка на разметке нейронной сети. Если соответствующая точка найдена в определенной области от верной, то считается, что сеть верно обнаружила точку (TP). В этом случае в качестве ошибки считается расстояние между найденной точкой и истинной точкой. Если точка, найденная сетью, отсутствует на врачебной разметке, то ответ считается ложно положительным (FP). Если сеть не обнаружила точку, присутствующую на правильной разметке, то ответ считается ложно отрицательным (FN).

Область принятия точки считается адаптивно, основываясь на сердечном ритме пациента. Для 70 ударов в секунду радиус области 150 мс. При более частом пульсе область делается меньше. Интервал в 150 мс выбран в соответствии с ANSI/AAMI-EC57:1998 [13].

Следующие метрики обычно используются в оценке разметки ЭКГ:

- 1) математическое ожидание ошибки m ,
- 2) дисперсия ошибки σ^2 ,
- 3) чувствительность Se :

$$Se = \frac{TP}{TP + FN} ,$$

- 4) положительная прогностическая ценность PPV :

$$PPV = \frac{TP}{TP + FP} .$$

Значения этих метрик для одной сети указаны в таблице 1, и они несколько хуже, чем у лучших прямых методов [9].

Так же для построения ансамбля использовалась F -мера:

$$F = 2 \frac{PPV \cdot Se}{PPV + Se} .$$

Результаты одной сети

Набор данных разбивался на тренировочную (134 пациента) и тестовую (66 пациентов) части. Батчи формируются из случайно выбранных 6-секундных интервалов. Алгоритм оптимизации – RMSProp [14], функция потерь – перекрестная энтропия.

Наличие высокочастотного шума (наводка электросети, 50 Гц), как было установлено, не оказывает значимого влияния на способность сети делать разметку. Таким образом, отсутствие необходимости фильтрации шума является преимуществом подхода глубокого обучения, так как снижает время, требуемое на предварительную обработку ЭКГ.

Таблица 1

**Результаты разметки тестовой выборки сети и ансамбля.
Усреднялись по 15 экспериментам**

	Одна сеть			Ансамбль сетей		
	Se	PPV	$m \pm \sigma^2$	Se	PPV	$m \pm \sigma^2$
Начало Р	95,20	82,66	$2,7 \pm 21,9$	97,97	90,48	$3,4 \pm 18,4$
Конец Р	95,39	82,59	$-7,4 \pm 28,6$	97,36	90,72	$-4,1 \pm 19,4$
Начало QRS	99,51	98,17	$2,6 \pm 12,4$	99,86	98,27	$1,7 \pm 10,0$
Конец QRS	99,50	97,96	$-1,7 \pm 14,1$	99,95	98,66	$-3,4 \pm 12,3$
Начало Т	97,95	94,81	$8,4 \pm 28,2$	93,77	96,28	$9,2 \pm 28,2$
Конец Т	97,56	94,96	$-3,1 \pm 28,2$	93,51	96,23	$-6,0 \pm 25,0$

Также было обнаружено, что наличие патологий (заболеваний) оказывает наибольший эффект на качество производительности нейронной сети. При анализе производительности сети на тестовом наборе данных оказалось, что все ошибочные разметки сети (F-мера меньше 0,99) происходили на ЭКГ с выраженными заболеваниями.

Если сравнить необработанный выходной сигнал сети (выход софт-макс слоя), полученный от ЭКГ без патологий с выходом от ЭКГ с выраженными патологиями, то можно видеть систематическую разницу в видах сигналов. В патологическом случае сигнал содержит ассиметричные всплески с низкой амплитудой, которые не влияют на итоговую разметку (рис. 2).

Такого не наблюдается на непатологических случаях: на них все всплески одинаково гладкие и большой амплитуды (рис. 1). Степень такого эффекта можно интерпретировать как «уверенность» сети.

Ансамбль

На сегодняшний день существует множество методов формирования ансамблей нейронных сетей (для обзора см. [15]). Выбранный метод определяет количество членов ансамбля, способ их взаимодействия и то, каким образом достигается разнообразие среди них (например, различные протоколы обучения [2], штрафы за корреляции [16] и т.д.). В данной статье различия достигаются разными обучающими примерами для членов ансамбля. Процедура формирования ансамбля спроектирована таким образом, чтобы каждая новая сеть ансамбля исправляла часть ошибок предыдущих.

После обучения F-мера базовой сети измерялась для каждого пациента тренировочной выборки, чтобы определить, какие случаи размечаются плохо. Затем начинается итеративная процедура построения ансамбля. Все пациенты с F-мерой 0,99 и выше удаляются из тренировочной выборки. Оставшаяся часть обучающей выборки используется в качестве отдельной выборки для новой сети ансамбля.

Новая сеть обучается на этой усеченной выборке, после чего результат сети также оценивается на каждом пациенте новой выборки, на основании чего выборка усекается ещё и создаётся новая сеть. Процедура повторяется, пока обучающая выборка не опустеет.

Когда ансамбль создан, результирующей разметкой для ЭКГ является усреднение выхода софтмакс слоя по всем членам ансамбля.




Рис. 3. Изменение количества пациентов в тренировочной выборке во время обучения ансамбля

Коррекция ошибок в действии

Из алгоритма построения ансамбля можно видеть, что он способен систематически корректировать некоторые ошибки, допущенные одиночной сетью. Члены ансамбля могут исправлять ошибки друг друга и, следовательно, исправлять ошибки базовой сети. Рисунок 4 демонстрирует это в ненормальном случае (пример из тестовой выборки). В таблице 1 показано, что в большинстве случаев ансамбль имеет лучшие значения метрик, чем базовая сеть.

Сети, добавленные в ансамбль на поздних итерациях, обучаются на очень маленьких выборках пациентов. Такая ситуация обязывает проверить степень переобучения в этих случаях. Для этого была разработана простая процедура, которая приблизительно оценивает степень переобучения сетей без необходимости использования тестовой выборки. Каждый участник ансамбля (кроме первого) обучается на некотором подмножестве тренировочной выборки. Это позволяет использовать оставшуюся часть тренировочной выборки в качестве проверочной, таким образом оценивая способность к обобщению. Визуализация результатов показана

на рис. 5. На данном рисунке изображено поведение ансамбля из 12 членов.

Как минимум, половина членов ансамбля обучалась менее чем на 10 пациентах (рис. 3). Можно видеть, что только две сети значительно переобучились (черный столбец близок к серому). Первая сеть не имеет отдельной проверочной выборки, поэтому нельзя сделать каких-то выводов о ней. Некоторые из оставшихся членов ансамбля могут делать хорошую разметку (F -мера больше 0,99) для десятков пациентов несмотря на то, что в их обучающую выборку входили только 2–3 пациента.




Рис. 4. Разметка ЭКГ с артефактами. Снизу врачебная разметка, посередине разметка одной сетью, сверху – ансамблем. Прямоугольники разных оттенков соответствуют разным компонентам сердечного цикла




Рис. 5. Гистограмма, иллюстрирующая способность к обобщению отдельных членов ансамбля. Черные столбцы соответствуют числу верно размеченных ЭКГ из выборки, на которой обучался данный член ансамбля. Серые – из всей обучающей выборки




Рис. 6. F -мера для каждого пациента отдельно. Слева результаты ансамбля. Справа результаты одной сети. Снизу тестовая выборка, сверху – обучающая

Чтобы получить качественное представление о том, за счет каких примеров достигается эффект коррекции ошибок ансамблем, было визуализировано его поведение на обучающей и тестовой выборках. Далее было проведено сравнение этого с поведением одиночной сети. Результат продемонстрирован на рис. 6. Правые изображения показывают, как одиночная сеть размечает тренировочную и тестовую выборки. Левые картинки показывают аналогичное для ансамбля сетей. В ансамбле значения F -меры сконцентрированы очень близко к значению 1. То есть использование ансамбля разделяет данные на два класса: плотное скопление примеров с небольшими ошибками (F -мера больше 0,9) в одной сети, которое при использовании ансамбля имеет F -меру, близкую к 1. Назовём такие случаи «простыми», оставшиеся – «сложными».

В целом F -мера ансамбля выше, чем у одной сети. Для одной сети это 0,94, для ансамбля больше 0,95. Но доля выбросов (ЭКГ с F -мерой меньше 0,9) при использовании ансамбля остаётся такой же, как у одиночной сети (около 16,5% на тренировочной выборке). Это значит, что ансамбль имеет лучшие значения метрики качества в большинстве случаев за счёт улучшения точности на «простых случаях».

Заключение

В этой работе был представлен исследование того, как происходит коррекция ошибок одной сети ансамблем (на примере типичного ансамбля и прикладной задачи). Наиболее важные результаты:

- 1) Коррекция ошибок происходит не равномерно по всей выборке, а по чётко различимым двум классам: «простые» (практически полностью исправляются ансамблем) и «сложные» (в среднем не исправляются).
- 2) Ошибка ансамбля наименьшая на здоровых пациентах, которые принадлежат к «простому» классу.
- 3) Присутствие редких классов заболеваний не обязательно относит ЭКГ к классу «сложных».

Количество примеров из «сложных» случаев может быть использовано в качестве основы для оценки качества внутреннего представления данных сетью данной архитектуры. Например, в рассматриваемом случае можно сделать вывод, что внутреннее представление одиночной сети имеет серьёзные недостатки, несмотря на то, что метрики показывают достаточно хорошие результаты.

Код проекта доступен на <https://github.com/Folifolo/SegmentationECG>.

Список литературы

1. Gorban A., Golubkov A., Grechuk B., Mirkes E., Tyukin I. Correction of ai systems by linear discriminants: Probabilistic foundations // Information Sciences. 2018. V. 466. P. 303–322.
2. Huang G., Li Y., Pleiss G., Liu Z., Hopcroft J.E., Weinberger K.Q. Snapshot ensembles: Train 1, get M for free. 2017. arXiv preprint arXiv:1704.00109
3. Zhang Q.S., Zhu S.C. Visual interpretability for deep learning: a survey // Frontiers of Information Technology & Electronic Engineering. 2018. V. 19, No. 1. P. 27–39.
4. Yap B.W., Rani K.A., Rahman H.A.A., Fong S., Khairudin Z., Abdullah N. N. An application of oversampling, undersampling, bagging and boosting in handling imbalanced datasets // Proceedings of the First International Conference on Advanced Data and Information Engineering (DaEng-2013). Springer. 2014. P.13–22.
5. Arnab A., Miksik O., Torr P. On the robustness of semantic segmentation models to adversarial attacks. 2017. Vol. 2. arXiv:1711.09856.
6. Yosinski J., Clune J., Nguyen A., Fuchs T., Lipson H. Understanding neural networks through deep visualization. 2015. arXiv:1506.06579.
7. Xu K., Ba J., Kiros R., Cho K., Courville A., Salakhudinov R., Zemel R., Bengio Y. Show, attend and tell: Neural image caption generation with visual attention // International conference on machine learning. 2015. P. 2048–2057.
8. Eastwood C., Williams C.K. A framework for the quantitative evaluation of disentangled representations. 2018.

9. Kalyakulina A., Yusipov I., Moskalenko V., Nikolskiy A., Kozlov A., Kosonogov K., Zolotykh N., Ivanchenko M. Lu electrocardiography database: a new open-access validation tool for delineation algorithms. 2018. arXiv:1809.03393.
10. De Chazal P., O'Dwyer M., Reilly R.B. Automatic classification of heartbeats using ecg morphology and heartbeat interval features // IEEE transactions on biomedical engineering. 2004. Vol. 51, N 7. P. 1196–1206.
11. Lenis G., Pilia N., Loewe A., Schulze W. H., Dossel O. Comparison of baseline wander removal techniques considering the preservation of st changes in the ischemic ecg: a simulation study // Computational and mathematical methods in medicine. 2017. Vol. 2017.
12. Rajpurkar P., Hannun A.Y., Haghpanahi M., Bourn C., Ng A.Y. Cardiologist-level arrhythmia detection with convolutional neural networks. 2017. arXiv:1707.01836
13. Association for the Advancement of Medical Instrumentation. NSI/AAMI EC57:1998/(R)2008 (Revision of AAMI ECAR:1987). 1999.
14. Tieleman T., Hinton G. Lecture 6.5-rmsprop: Divide the gradient by a running average of its recent magnitude // COURSERA: Neural networks for machine learning. 2012. Vol. 4, N 2. P. 26–31.
15. Sagi O., Rokach L. Ensemble learning: A survey // Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery. 2018. Vol. 8, N 4. P. e1249.
16. Liu Y., Yao X. Ensemble learning via negative correlation // Neural networks. 1999. Vol. 12, N 10. P. 1399–1404.

**А. Г. КОРОТКОВ, М. А. ОСИПОВА,
М. А. ЗАКС, Г. В. ОСИПОВ**

Нижегородский государственный университет им. Н.И. Лобачевского
koralg81@gmail.com

АНСАМБЛЬ ВОЗБУЖДАЮЩЕ СВЯЗАННЫХ НЕЙРОНОПОДОБНЫХ ЭЛЕМЕНТОВ*

В работе предложена модель ансамбля нейроноподобных элементов, состоящего из двух возбуждающе связанных фазовых осцилляторов. Связь между элементами ансамбля моделируется с помощью функции одной переменной – фазы пресинаптического элемента.

Ключевые слова: нейронный ансамбль, возбуждающие связи, уравнение Адлера.

Введение

В исследовании нейронной активности в качестве модели нейрона часто используют модели типа Ходжкина-Хаксли [1]. Нас интересуют различные устойчивые режимы с определённой разницей фаз между нейронами. Наиболее интересные и важные режимы в таких моделях связаны с их фазовой динамикой. В данной работе предлагается модель пары связанных возбуждающими связями нейронов в виде системы двух связанных фазовых осцилляторов.

На рис. 1 представлена временная реализация изолированного нейрона, описываемого системой Ходжкина–Хаксли, в режиме тонической спайковой активности. Прежде всего при исследовании нейронной активности нас интересуют устойчивые режимы эволюции разности фаз элементов, поэтому для удобства фазу в таких системах вводят как привязку к характерным событиям: спайку в режиме тонической спайковой активности или началу пачки в режиме пачечной активности. Другой способ введения фазы представлен на рис. 2. Тут рассматривается проекция траектории, представленной на рис. 1, на плоскость (V, n) двух переменных системы Ходжкина–Хаксли. Начало координат выбрано внутри предельного цикла. Ось направлена горизонтально вправо. Фаза колебаний вводится как угол между осью и радиус-вектором фазовой точки на траектории.

Изменение фазы, представленное на рис. 2, хорошо описывается уравнением Адлера [2]:

* Данная работа выполнена при поддержке министерства образования и науки РФ, проект № 14.Y26.31.0022.

$$\dot{\varphi} = \gamma - \sin \varphi, \quad (1)$$

где γ – собственная частота осциллятора.




Рис. 1. Проекция временной реализации изолированного нейрона, описываемого системой Ходжкина–Хаксли, в режиме тонической спайковой активности на трёхмерное пространство: time – время, V – напряжение, n – константа открытия Na-канала. В проекции на плоскость (time, V) видно, что точка на траектории быстро пробегает петли (соответствует спайкам) и много времени проводит между ними (межспайковый интервал)




Рис. 2. Проекция траектории, представленной на рис. 1, на плоскость (V , n). Данная траектория соответствует предельному циклу в системе Ходжкина–Хаксли. При этом видно, что большую часть времени точка на траектории проводит в нижней части цикла (соответствует проекции межспайкового интервала) и быстро проходит по остальной части цикла (соответствует спайку)

С помощью замены переменных уравнение Адлера может быть приведено к уравнению тета-нейрона [3].

Таким образом, от сложной многомерной динамической системы можно перейти к одномерной динамической системе с простой динамикой, заданной на окружности. В данной работе рассматривалось введение фазы для систем, показывающих тоническую спайковую активность, но аналогично можно ввести фазу и для систем с пачечной активностью. Спайк в системе Адлера будет соответствовать началу пачки в исходной – такое приближение вполне удовлетворяет задаче исследования ритмической активности.

Модель ансамбля

Будем рассматривать ансамбль из двух фазовых осцилляторов. Фазовым пространством такой системы является тор. Под синфазным синхронным режимом будем понимать режим, которому соответствует предельный цикл, на котором фазы обоих элементов совпадают: $\varphi_1(t) = \varphi_2(t)$. Под противофазным синхронным режимом будем понимать режим, которому соответствует предельный цикл, на котором фаза одного элемента отстаёт от фазы другого на половину периода этого цикла: $\varphi_1(t) = \varphi_2(t + \frac{T}{2})$, где T – период этого предельного цикла.

Предположим, что в фазовом пространстве системы существует противофазный цикл периода T . Пусть $(\varphi_1^*, \varphi_2^*)$ – произвольная точка на нём, соответствующая некоторому моменту времени t^* . Тогда, как следует из определения, точка $(\varphi_2^*, \varphi_1^*)$ также принадлежит этому предельному циклу и соответствует моменту времени $t^* + \frac{T}{2}$. То есть этот цикл вместе с любой своей точкой содержит и точку, симметричную ей относительно линии $\varphi_1 = \varphi_2$ (в частном случае обе эти точки могут совпасть и лежать на линии симметрии).

Из определения следует, что в фазовом пространстве системы не могут сосуществовать два или более противофазных предельных циклов.

Фазовым пространством уравнения (1) является окружность. При $\gamma < 1$ в фазовом пространстве существуют два состояния равновесия: $\varphi_1 = \arcsin \gamma$ (устойчивое) и $\varphi_2 = \pi - \arcsin \gamma$ (неустойчивое) (такой элемент можно считать возбудимым); при $\gamma > 1$ состояний равновесия нет. На рис. 3 представлены фазовые портреты элемента при различных значениях γ .




Рис. 3. Фазовые портреты элемента при различных значениях параметра γ

Математической моделью ансамбля из двух идентичных нейронов будет следующая система дифференциальных уравнений:

$$\begin{cases} \dot{\phi}_1 = \gamma - \sin \phi_1 + dI(\phi_2), \\ \dot{\phi}_2 = \gamma - \sin \phi_2 + dI(\phi_1), \end{cases}$$

где $d > 0$ – коэффициент, характеризующий силу возбуждающей связи, $I(\varphi)$ – функция, задающая связь между элементами:

$$I(\varphi) = \frac{1}{1 + e^{k(\cos \frac{\varphi}{2} - \cos(\varphi - \alpha - \frac{\varphi}{2}))}}.$$

График зависимости этой функции от фазы φ приведён на рис. 4.




Рис. 4. Зависимость функции связи от фазы

Передача активности между элементами происходит следующим образом. Когда для фазы пресинаптического (активного) элемента выполнено условие $\alpha \leq \varphi_i \leq \alpha + \delta$, то активируется следующий элемент. На рис. 5 представлено разбиение фазового тора на области активирования. Данный тип связи был использован в работе [4].




Рис. 5. Интервалы активирования элементов на фазовом торе

Фазовым пространством системы является двумерный тор. Так как система инвариантна относительно циклической перестановки индексов, то прямая $\varphi_1 = \varphi_2$ является инвариантной (причём это выполняется для функции $I(\varphi)$ произвольного вида) и фазовый портрет системы симметричен относительно этой прямой.

Примем $\gamma = 0.7$, $d = 1$ (так как $d > 0$ и $\gamma < 1$, то связь возбуждающая), $k = 1000$. Будем исследовать влияние параметров α и δ ($0 \leq \alpha, \delta < 2\pi$) на динамику ансамбля*.

Общая динамическая картина

На рис. 6 приведена бифуркационная диаграмма исследуемой системы. На линии l_1 выше точки пересечения с линиями l_2 и l_7 в системе происходит бифуркация, в результате которой синфазный и противофазный циклы теряют свою устойчивость (то есть с одной стороны от l_1 устойчивым является синфазный цикл, а противофазный – неустойчивым, с другой стороны – наоборот). На линиях l_2 и l_7 происходит седло-узловая бифуркация на инвариантной замкнутой кривой, в результате которой рождаются два состояния равновесия на линии $\varphi_1 = \varphi_2$. На линиях l_3 и l_6 происходит бифуркация «вилка» состояния равновесия, в результате которой из состояния равновесия, лежащего на линии $\varphi_1 = \varphi_2$, рождаются ещё два состояния равновесия, не лежащие на линии $\varphi_1 = \varphi_2$. На линии l_4 происходит бифуркация потери устойчивости противофазного цикла. На линии l_5 происходит бифуркация рождения противофазного цикла из гетероклинического цикла.

* Из системы следует, что α может быть определено с точностью до 2π . Поэтому примем, что пространством параметров является цилиндр.




Рис. 6. Бифуркационная диаграмма.

В области А есть устойчивый синфазный и неустойчивый противофазный режимы.

В области В – устойчивый противофазный и неустойчивый синфазный.

В области С – устойчивый противофазный режим, а также неустойчивое и седловое состояния равновесия.

В области D – устойчивый противофазный режим, а также устойчивое, неустойчивое и два седловых состояния равновесия.

В области E – устойчивое, неустойчивое и два седловых состояния равновесия.

В области F – неустойчивый противофазный режим, а также устойчивое и седловое состояния равновесия.

В области G – устойчивый противофазный режим, а также два устойчивых и два седловых состояния равновесия.

В области H – неустойчивый противофазный режим, а также два устойчивых и два седловых состояния равновесия.

В области I – неустойчивый противофазный режим, а также устойчивое, неустойчивое и два седловых состояния равновесия.

В области J – неустойчивый противофазный режим, а также два устойчивых и два седловых состояния равновесия.

В области K – устойчивый противофазный режим, а также два неустойчивых и два седловых состояния равновесия.

В результате бифуркации, задаваемой условием $\alpha \approx \pi - \arcsin \gamma$, из состояния равновесия на линии $\varphi_1 = \varphi_2$ с большими координатами рождаются два состояния равновесия, не лежащих на этой линии и симметричных друг другу. В результате бифуркаций, задаваемых условиями $\alpha + \delta \approx \arcsin \gamma$ и $\alpha + \delta \approx 2\pi + \arcsin \gamma$, из состояния равновесия на линии $\varphi_1 = \varphi_2$ с меньшими координатами также рождаются два состояния равновесия, не лежащих на этой линии и симметричных друг другу.

Синфазный синхронный режим

Как было указано в предыдущем разделе, в фазовом пространстве модели существует устойчивый синфазный цикл. Ему соответствует синфазный синхронный режим.

Этот режим возникает в результате седло-узловой бифуркации на инвариантной кривой (также в её результате пропадает режим отсутствия активности).

Противофазный синхронный режим

Ещё одним синхронным режимом, наблюдаемым в системе, является противофазный режим. В фазовом пространстве модели ему соответствует устойчивый противофазный предельный цикл. На рис. 7 приведены его фазовый портрет и временные реализации.




Рис. 7. Фазовый портрет и временные реализации противофазного синхронного режима

Стоит отметить, что устойчивый противофазный цикл может сосуществовать с устойчивым состоянием равновесия, то есть в системе имеется бистабильность.

Выводы

В работе предложена новая модель ансамбля из двух возбуждающе связанных нейроноподобных элементов, задаваемых фазовым уравнением. Связь между элементами является функцией фазы пресинаптического элемента. Были обнаружены устойчивые синфазный и противофазный синхронный режимы, а также режим отсутствия активности.

Список литературы

1. Izhikevich E. M. Dynamical systems in neuroscience: the geometry of excitability and bursting. The MIT Press. 2007. P. 457.
2. Adler R. A study of locking phenomena in oscillators // Proceedings of the I.R.E. and Waves and Electrons. 1946. V. 34. P. 351–357.
3. Ermentrout G. B., Kopell N. Parabolic bursting in an excitable system coupled with a slow oscillation // SIAM Journal on Applied Mathematics. 1986. V. 46, N 2. P. 233–253.
4. Korotkov A. G., Kazakov A. O., Levanova T. A., Osipov G. V. The dynamics of ensemble of neuron-like elements with excitatory couplings // Communications in Nonlinear Science and Numerical Simulation. 2019. V. 71. P. 38–49.

А. А. ТЕЛЬНЫХ^{1,2}, И. В. НУЙДЕЛЬ^{1,2}, О. В. ШЕМАГИНА^{1,2}

¹Федеральный исследовательский центр Институт прикладной физики
Российской академии наук (ИПФ РАН), Нижний Новгород

²Нижегородский государственный университет им. Н.И. Лобачевского
nuidel@appl.sci-nnov.ru

БИОМОРФНАЯ МОДЕЛЬ КОРТИКАЛЬНОЙ КОЛОНКИ ДЛЯ СЕМАНТИЧЕСКОГО АНАЛИЗА ИЗОБРАЖЕНИЙ*

В работе приведена биоморфная модель кортикальной колонки, которая имеет топическую структуру. В процессе обучения на объекты распознавания активируются и усиливаются веса восходящих связей, и таким образом формируется колонка. Процесс обучения визуализирован: возможно наглядно представить формирование колонки – детектора конкретных стимулов: лицо, цифра, число и т.п.

Ключевые слова: кортикальная колонка, нейронная сеть, семантический анализ изображений.

Введение

За последние сто лет к настоящему времени в ходе биологических функциональных и морфологических исследований накоплено огромное количество детальных знаний о структуре и функциях мозга. Нейроны представляют собой элементарные обрабатывающие единицы в центральной нервной системе, которые связаны друг с другом. Lorento de No [1] обнаружил в коре головного мозга определенную вертикальную упорядоченность нейронов, образующих узкий цилиндр клеток и занимающих несколько корковых слоев. Hubel и Wiesel [2] в электрофизиологических исследованиях обнаружили функциональную упорядоченность нейронов, лежащих друг под другом, в зрительной области коры мозга. Исследования слуховой и кожной коры также подтвердили существование упорядоченных вертикальных узких колонок. Позднее Mountcastle [3], исследуя у наркотизированных кошек импульсную активность нейронов соматосенсорной зоны коры, получил прямые доказательства того, что основной структурно-функциональной единицей в этой области является вертикально ориентированная колонка, идущая через все клеточные слои. Функциональная общность нейронов в кортикальной колонке разных проекционных зон подтверждается и тем, что они обладают дирекциональной избирательностью в отношении целого ряда параметров стимула. Особен-

* Данная работа выполнена при поддержке Министерства образования и науки РФ, проект №14.Y26.31.0022.

но это характерно для кожной и зрительной проекционных зон коры [1–3] (рис. 1 а).




Рис. 1. а – модульная организация коры головного мозга. Столбики модуля распознают линии и решетки всех ориентаций от 0 до 180 градусов через каждые 6 градусов [3]; б – схема связей в одной колонке между слоями коры на шести уровнях. Треугольники – пирамидные клетки. Чёрным цветом показаны возбуждающие связи, серым цветом показаны интернейроны соответствующих уровней коры и тормозные связи. Th – таламус, от которого идут стрелки таламо-кортикальных входов сенсорных сигналов [4, 5]

Согласно полученным нейрофизиологическим данным [4, 5], диаметр микроколонки $d = 30 \cdot 10^{-6}$ м, и она насчитывает 80–100 нейронов, расположенных на пяти клеточных уровнях. Микроколонки объединены в макромодули (макроколонки) $D = 500 - 1000 \cdot 10^{-6}$ м, содержащие ~100 микроколонок. Все клетки в пределах одной микроколонки связаны с одним и тем же рецептивным полем; смежные микроколонки могут быть связаны с разными рецептивными полями. Выходящий из таламуса аксон подходит к 100–300 микроколонкам.

Итак, показано, что в когнитивных системах живых организмов структурно-функциональные единицы обработки информации – колонки (рис.1), которые состоят из возбуждающих и тормозных нейронов, а также некоторых других видов клеток, например, звёздчатых клеток и глиальных клеток – астроцитов [4, 5].

При построении искусственных когнитивных систем используется подход, основанный на формальных моделях нейрона, который является нелинейным сумматором входных сигналов. В моделях устанавливаются и меняются веса связей нейрона в процессе процедуры обучения [6–10].

Подобный подход не лишен недостатков, неизбежных при редукции модели. В частности, системы, построенные на функциональной модели нейрона, не могут воспроизводить все многообразие когнитивных функций, которые встречаются в живых организмах, так как, например, нет учета различных типов активирующих и тормозящих медиаторов, разнообразия межклеточных взаимодействий и соединений.

Учитывая колончатую организацию структурных единиц обработки информации в искусственных когнитивных системах, мы создаем наглядную биоморфную модель сетей нейронов. С одной стороны, такая модель иллюстрирует процессы передачи и обработки информации в мозге человека и животных. С другой стороны, она имеет все характеристики технической системы семантического анализа изображений [6–8].

Описание биоморфной модели кортикальной колонки

Как известно, типичным для неокортекса является наличие шести слоев, которые различаются между собой формой входящих в них клеток и их функциональным назначением, которые сгруппированы во множество колонок (рис.16) [4, 5].

Предполагается, что одной из функциональных операций кортикальной колонки является способность реагировать на сложные сигналы, поступающие от сенсорной системы таким образом, что сигналы, соответствующие какому-то объекту или состоянию, вызывают активацию всей колонки, а сигналы, соответствующие другому объекту или состоянию, не приводят к активации всей колонки. При этом для распознавания каждого объекта или состояния требуется одна или несколько кортикальных колонок. Для создания искусственной кортикальной колонки взята за основу вышеописанная структура.

Нейроноподобный элемент – это пороговый формальный нейрон-сумматор с нелинейной пороговой функцией активации [9, 13].

Послойное описание модели

1. Полиморфный слой (6). Полиморфный слой состоит из нейроноподобных элементов (нейронов), которые выполняют суммирование информации с некоторого участка изображения прямоугольной формы с произвольными размерами. Каждый нейроноподобный элемент в этом слое может быть соединен с различным числом нейронов внутри слоя от четырех до 1024.
2. Внутренний слой пирамидных клеток (внутренний пирамидный слой 5) содержит нейроны, которые соединены с различным количеством нейронов полиморфного слоя (от двух до девяти), образующих его рецептивное поле, и в зависимости от их состояния генерируют кодовое описание этого состояния.

3. Кодовое описание состояния нейронов внутреннего пирамидного слоя (5) передается на один или несколько нейронов внутреннего зернистого слоя (4), которые, в зависимости от этого кодового состояния, активируются исключительно на заданный вид сигнала, причем «осмысленная» активация нейронов этого слоя становится возможной в результате обучения всей нейросети.
4. Нейроны наружного слоя пирамидных клеток (наружный пирамидный слой 3) представляют классические искусственные нейроны типа «integrate-and-fire», которые соединены с несколькими нейронами предыдущего слоя.
5. Нейроноподобные элементы наружного зернистого слоя (2) также представляют классические искусственные нейроны типа «integrate-and-fire», но собирающие информацию с нейронов предыдущего слоя и с нейронов своего слоя, которые относятся к другим кортикальным колонкам. Как правило, в этом слое присутствует один нейрон. Но был рассмотрен случай с двумя нейронами, которые взаимно усиливают или подавляют активность всей иерархии.
6. Элементы шестого слоя (1) представляют собой дендритные деревья нейронов пятого слоя (2), которые передают активирующие или подавляющие сигналы на соседние колонки.

Возможности биоморфной модели кортикальной колонки

Типичная искусственная биоморфная модель кортикальной макроколонки содержит порядка 1000 нейронов различных видов и выполняет строго определенную функциональную операцию: обнаружение объектов заданного типа под определенным углом зрения.

Построена упрощенная модель нейронной сети внутри кортикальной колонки и состоящего из таких искусственных колонок участка коры, которые ориентированы на обработку поступающей сенсорной информации в виде изображения. В результате работы подобной структуры формируется семантическое описание обрабатываемого изображения, которое представлено активностью различных элементов моделируемого участка коры. Активность различных колонок такой искусственной структуры соответствует узнаванию того или иного объекта на сцене и определению его свойств. В модели каждая отдельная колонка соответствует одному объекту из известного системе распознавания семантического словаря. Семантический словарь – это набор объектов, наблюдаемых под определенным углом зрения. Искусственная структура построена как сеть из вертикально ориентированных колонок с четкими функциональными ролями слоев внутри них.

Внутри каждой колонки обеспечивается: выделение семантических признаков; возбуждение или торможение других колонок, участвующих в

процессе обработки поступающей визуальной информации; формирование новых связей между нейронами; изменение весов существующих связей и выделение наиболее существенных признаков распознаваемых объектов.

Важной особенностью представленной модели является то, что структура кортикальной колонки имеет универсальную природу и позволяет, используя небольшой набор типов нейронов, выполнять операции анализа изображений с целью обнаружения объектов различных типов и указания их характерных свойств.

Типы нейронов отличаются видом рецептивных полей. На рис. 2 приведены примеры рецептивных полей (С-код рецептивного поля) из множества рецептивных полей 2^9 , которые используются для кодирования информации на изображении.




Рис. 2. Примеры рецептивных полей, которые используются для кодирования информации на изображении

Примеры объектов различных типов: лица людей, пешеходов, автомобилей, номерных знаков, отдельных цифр и т.п. Свойства объектов: цвет, размер, местоположение, пол, возраст для людей и т.д.

Реализован программный комплекс для создания нейронных сетей, построенных по принципу кортикальной колонки, которые активируются только при наличии сигналов определенного вида.

Разработанная система – это биоморфная модель взаимодействующих иерархических однотипных колонок. Она включает в себя несколько типов нейроноподобных элементов, работающих на своем уровне иерархии, которые выполняют простые операции по преобразованию информации.

Показано, что такая модель из одинаковых элементов, сгруппированных послойно, демонстрирует способность распознавать объекты заданных типов и их свойства [6–8] (селективность и семантическая классификация изображений).

Назначение биоморфной модели кортикальной колонки

Биоморфная искусственная модель кортикальной колонки предназначена для обнаружения объектов, заданных типов на изображении. Каждому объекту из реального мира соответствует одна или несколько искусственных кортикальных колонок, которые активируются, если на их вход

подается сигнал, соответствующий объекту заданного типа. На рис. 3 показаны области активности кортикальных колонок, которые обучены на различные объекты реального мира.



Рис. 3. Отклик двух кортикальных колонок на объекты реального мира различных типов: автомобили и лица людей анфас и в профиль

В настоящий момент система сканирования последовательно подает на вход набору искусственных кортикальных колонок фрагменты изображения. Для тех фрагментов, которые приводят к активности искусственных нейронов во всех слоях кортикальной колонки, выдается сигнал о том, что в этих фрагментах находится объект того типа, который ассоциирован с активированной колонкой. Таким образом, анализируя активность множества искусственных кортикальных колонок, мы в итоге можем получить семантическое описание изображения, которое состоит из набора активности искусственных кортикальных колонок, связанных с местоположением различных объектов на изображении и их размерами.

Разработанный программный комплекс, обеспечивающий визуализацию работы искусственной биоморфной макроколонки, позволяет проводить исследования по её обучению. Например, влияние свойств нейроноподобных элементов (рецептивных полей и функции активации) на точность распознавания объектов заданного типа, подавление ошибок первого и второго рода в процессе формирования и функционирования макроколонки. Заметим, что подавление ошибок осуществляется без переобучения всей системы, а исключительно за счет роста микроколонки «вглубь и вширь», то есть вовлечения в структуру колонки новых элементов.

Помимо процедуры дообучения нейросети в процессе ее функционирования, программный комплекс позволяет проводить исследования быстрействия и эффективности работы всей системы, оценивая число нейроноподобных элементов, вовлеченных в работу системы во время распознавания. Другими словами, оценивается активность колонки при наблюдении ложных объектов, что позволяет сделать выводы о том, каким образом следует оптимизировать или саму модель колонки, или про-

цедуру обучения для минимизации этой активности.

Визуализация искусственной кортикальной колонки

Для выполнения задач по исследованию работы искусственной кортикальной колонки в разработанном программном комплексе имеется возможность визуализации активности составных частей колонки в двумерном и трехмерном представлении. Помимо визуализации внутреннего содержимого колонки можно также извлекать информацию о параметрах структуры, таких как

- 1) назначение;
- 2) количество нейроноподобных элементов в различных слоях;
- 3) пороги срабатывания нейроноподобных элементов в различных слоях;
- 4) функции активации нейроноподобных элементов;
- 5) распределение нейроноподобных элементов по полю зрения.

Ниже на рис. 4–6 приведены различные режимы визуализации работы колонки.




Рис. 4. а – отображение числа элементов в наружном пирамидном слое, полученных в результате процедуры обучения; б – пример отображения распределения местоположений элементов внутреннего пирамидного слоя, полученных в результате процедуры обучения на заданный объект; в- пример отображение расположения элементов полиморфного слоя, связанных с конкретным элементом наружного пирамидного слоя




Рис. 5. а - Пример отображения всей колонки в трехмерном виде; б - пример отображения заданного элемента и его связей в трехмерном виде; в - пример отобра-

жения заданного элемента и его связей в двумерном виде; г - пример отображения нескольких элементов со своими связями в двумерном виде



Рис. 6. Визуализация работы искусственной кортикальной колонки. Активные элементы внутреннего слоя отображаются – черные точки среди множества неактивных (серых) элементов; активные элементы пирамидного слоя отображаются черными кружками в верхнем слое

Визуализация работы искусственной кортикальной колонки

Визуализация работы искусственной кортикальной колонки представляет собой динамический процесс анализа заданного фрагмента изображения, при котором система визуализации отображает активные состояния элементов искусственной кортикальной колонки в текущий момент времени, одновременно с отображением результата ее работы на исходном изображении.

Выводы и перспективы исследования

Реализован программный комплекс для создания нейронных сетей, построенных по принципу кортикальной колонки, которые активируются только при наличии сигналов определенного вида. Разработанная система - это биоморфная модель взаимодействующих иерархических однотипных колонок. Она включает в себя несколько типов нейроноподобных элементов, работающих на своем уровне иерархии, которые выполняют простые

операции по преобразованию информации. Показано, что модель из одинаковых элементов, сгруппированных послойно, демонстрирует способность распознавать объекты заданных типов и их свойства [6-8] (селективность и семантическая классификация изображений).

Как известно, мозг анализирует данные разных модальностей (звуковые, видео, тактильные, обонятельные стимулы). Первичное кодирование информации производится детекторами, расположенными в соответствующих зонах первичной коры. Далее в искусственной кортикальной колонке детектирование и распознавание инвариантно к сенсорной модальности стимула. В разработанной искусственной системе распознавания можно смоделировать и визуализировать ситуации, когда «разнесенные» в пространстве признаки поля нейроноподобных элементов, организованные в колончатые структуры с восходящими связями, в итоге зажигают на выходе одну клетку. Таким образом, на модели можно проиллюстрировать формирование «концептуальных ячеек», идея о которых впервые была высказана Konorski J. еще в 1967 году [11]. Сейчас этот факт подтвержден нейрофизиологическими исследованиями о существовании нейронов-детекторов стимулов разных модальностей: если два (или несколько) стимулов (концепты concepts) часто появляются вместе, то клетка будет реагировать на оба (все). Более того, эта связь между концептами может быть запомнена и при однократном воздействии [12, 13].

Разработанный программный комплекс активно используется для распознавания объектов заданного типа на статических изображениях и видеофрагментах. Возможны следующие направления дальнейших исследований: развитие технической системы распознавания и ее практическое применение для распознавания объектов заданного типа; разработка новых детекторов объектов на изображении (детектор дыма, нештатных ситуаций, например, драки, и т.п.); иллюстрация на модели процесса формирования «концептуальных ячеек»; поиск по данным литературы новых нейрофизиологических и морфологических данных об устройстве колонок и приведение результатов работы модельной колонки в соответствие с ними.

Коллектив авторов благодарит Яхно В.Г. за содержательное обсуждение работы.

Список литературы

1. Lorento de No R. Analysis of the activity of the chains of internuncial neurons // J. Neurophysiol. 1939. V.1. P. 208-217.
2. Hubel D.H., Wiesel T.N. Receptive fields, binocular interaction and functional architecture in the cat's visual cortex // J. Physiol. (Gr. Brit.). 1962. V. 160, N 1. P. 106-154.
3. Mountcastle V.B. Modality and topographic properties of single neurons of cat's somatic sensory cortex. // J. Neurophysiol. 1957. V. 20, N 4. P. 408 - 434.

4. Tobias C. Potjans and Markus Diesmann. The Cell-Type Specific Cortical Microcircuit: Relating Structure and Activity in a Full-Scale Spiking Network Model // *Cerebral Cortex*. March 2014.24. P.785–806. doi:10.1093/cercor/bhs358
5. Alex M. Thomson and Christophe Lamy. Functional maps of neocortical local circuitry// *Frontiers in Neuroscience*. 2007. V. 1, iss. 1. P. 19–42. doi: 10.3389/neuro.01.1.1.002.2007.
6. Беллюстин Н.С., Калафати Ю.Д., Ковальчук А.В., Тельных А.А., Шемагина О.В., Яхно В.Г. Системы обнаружения, сопровождения и кластеризации объектов на основе нейроноподобного кодирования // *Информационно-измерительные и управляющие системы*. 2010. Т. 8, № 2. С. 29-34.
7. Bellustin N., Kalafati Y., Kovalchuck A., Telnykh A., Shemagina O., Sharma P., Vaish A., Verma S. and Yakhno V. Instant Human Face Attributes Recognition System // *International Journal of Advanced Computer Science and Applications (IJACSA)*. Special Issue on Artificial Intelligence. 2011. P. 112–120.
8. Belliustin N. S., Kalafati Yu. D., Telnykh A. A., and Shemagina O. V. Neuron Like Algorithms of Adaptive Segmentation and Semantic Description of Images in the —Adult Image Recognition Problem // *Optical Memory and Neural Networks (Information Optics)*. 2014. V. 23 (1). P. 26–33.
9. Яхно В.Г. Модели нейроноподобных систем. Динамические режимы преобразования информации // *Материалы школы «Нелинейные волны 2002»*. Нижний Новгород: ИПФ РАН. 2003. С. 90–114.
10. Кузнецова Г.Д., Нуйдель И.В., Соколов М.Е., Яхно В.Г. // *Моделирование динамических процессов преобразования сенсорных сигналов в таламо-кортикальных сетях* // *Лекции по нейроинформатике*. Москва : НИЯУ МИФИ, 2014. С. 150–178, ISBN 978–5–7262–1897–7.
11. Konorski J. Integrative activity of the brain; an interdisciplinary approach. Chicago: University of Chicago Press; 1967.
12. Quian Quiroga R, Fried I, Koch C. Brain cells for grandmother // *Scientific American*. 2013.308(2). P. 31–35. Нейроны для бабушки - Р.К. Квиорога, К.Кох, И. Фрид. В мире науки. 2013, апрель. С. 47-52.
13. Gorban A.N., Makarov V.A., Tyukin I.Y. The unreasonable effectiveness of small neural ensembles in high-dimensional brain// 2018. Doi 10.1016/j.plrev.2018.09.005. <https://arxiv.org/abs/1809.07656>

М. И. БОЛОТОВ, Г. В. ОСИПОВ

Нижегородский государственный университет им. Н.И. Лобачевского
maksim.bolotov@itmm.unn.ru

КОЛЛЕКТИВНАЯ ДИНАМИКА ИМПУЛЬСНО-СВЯЗАННЫХ НЕЙРОНОПОДОБНЫХ ЭЛЕМЕНТОВ*

Рассматривается коллективная динамика в ансамбле импульсно-связанных через общее поле нейроноподобных элементов. Проводится численное изучение динамики ансамбля при различных фиксированных значениях параметров системы. На основе полученных данных в зависимости от значения параметра синхронности делается вывод о коллективном поведении элементов ансамбля, характере эволюции поля ансамбля, зависимости поведения поля ансамбля от синхронности элементов ансамбля.

Ключевые слова: нейроноподобный элемент, импульсная связь, общее поле, синхронизация.

Введение

Под синхронизацией обычно понимается процесс достижения связанными объектами единого ритма функционирования. Синхронизация – это очень распространенное явление в природе и технике [1–3]. В нейронауках синхронизация – это процесс, который характеризуется регулярной или хаотической одновременной активацией нейронов или популяций нейронов. Синхронная активность в нейронных сетях является главным механизмом образования ритмов в мозге. Известно, что ритмы играют важную роль в процессах передачи и обработки информации в центральной нервной системе (память, сон, внимание, когнитивные восприятия, пространственная навигация и т. д.). С другой стороны, синхронизация может иметь патологические проявления: тремор, эпилепсия, расстройства высшей мозговой функции (шизофрения, аутизм) и т. д.

Исследованию синхронного и асинхронного поведения ансамбля глобально связанных нейроноподобных элементов посвящена данная статья.

Постановка задачи и модель

При исследовании синхронного поведения решающую роль играет фазовая динамика как отдельного элемента, так и всего ансамбля. Для описания фазовой динамики используются модели в виде фазового осцилля-

* Данная работа выполнена при поддержке Министерства образования и науки Российской Федерации, проект № 14.Y26.31.0022.

тора, тета-нейрона и др. В настоящей статье мы используем модель в виде уравнения Адлера:

$$\dot{\varphi}_i = \gamma_i - \sin \varphi_i + g E(t), \quad (1)$$

где $i = 1, \dots, N$, $\gamma_i > 1$ – параметр, определяющий поведение элемента ансамбля при отсутствии связи, g – параметр, характеризующий силу связи между нейронами, $E(t)$ – динамическая переменная, задающая состояние общего поля ансамбля.

Рассмотрим ансамбль, который состоит из N элементов, каждый из которых связан через общее поле со всеми другими нейронами. Примем, что все элементы системы (1) идентичны, т.е. $\gamma_i = \gamma > 1$. Состояние i -го элемента ансамбля задается переменной φ_i , которая принимает значения из отрезка $[0; 2\pi]$. Уравнения (1) определяют состояния нейронов на отрезке $[0; 2\pi]$. Как только φ_i достигает значения 2π , с i -го осциллятора в уравнение для общего поля подается импульсное воздействие.

Эволюция поля ансамбля задается уравнением

$$\frac{d^2 E(t)}{dt^2} + 2\alpha \frac{dE(t)}{dt} + \alpha^2 E(t) = \frac{\alpha^2}{N} \sum_{n|t_n < t} \delta(t - t_n), \quad (2)$$

где $\alpha > 1$ – положительный параметр, характеризующий диссипацию в уравнении (2), t_n – момент времени поступления n -го импульса.

Таким образом, рассматривается система нейроноподобных элементов, на каждый из которых подается внешнее воздействие, которое определяется текущим состоянием всех нейронов.

Введем следующую переменную $Q = \alpha E + \dot{E}$. При интегрировании уравнения (2) от момента времени t_n до момента $t < t_{n+1}$ (t_n – момент времени, непосредственно следующий за испусканием n -го импульса) получается

$$E(t) = (E(t_n) + (t - t_n)Q(t_n))e^{-\alpha(t-t_n)}, \quad (3)$$

$$Q(t) = Q(t_n)e^{-\alpha(t-t_n)}. \quad (4)$$

В момент времени t_{n+1} значение переменной $Q(t)$ изменяется следующим образом

$$Q(t_{n+1}) = Q(t_n)e^{-\alpha(t_{n+1}-t_n)} + \frac{\alpha^2}{N}, \quad (5)$$

где $\tau(n) = t_{n+1} - t_n$ – межимпульсный интервал, первое слагаемое отвечает за затухание поля E , а второе слагаемое – за величину внешнего импульсного воздействия.

Будем называть динамику элементов ансамбля синхронной, если разность между переменными состояниями индивидуальных нейронов мала, т.е.

$\varphi_1 \approx \varphi_2 \approx \dots \approx \varphi_N$. Введем параметр синхронности μ следующим образом

$$\mu = \frac{\sum_{i,j} \rho(\varphi_i - \varphi_j)}{N \sum_i \rho(\varphi_i^l - \varphi_i^l)}, \quad (6)$$

где $\rho(\varphi_i, \varphi_j) = |\varphi_i - \varphi_j| \bmod 2\pi$ – расстояние между φ_i и φ_j на окружности $[0; 2\pi]$, φ_i – состояние i -го элемента в фиксированный момент времени, φ_i^l – состояние i -го элемента, соответствующее линейному распределению фаз на $[0; 2\pi]$. Данный параметр синхронности выбран таким образом, чтобы линейному распределению фаз нейронов (splay state), т.е. состоянию, при котором среднее расстояние от фазы каждого элемента до фазы другого элемента было наибольшим, соответствовало наибольшее значение параметра синхронности (в данном случае $\mu = 1$), а состоянию, когда фазы всех элементов совпадают, наименьшему значению параметра синхронности ($\mu = 0$). Таким образом, $\mu = 1$ соответствует полностью асинхронному, а $\mu = 0$ полностью синхронному распределению фаз нейронов.

Синхронная динамика в ансамбле

Зафиксируем параметр $g = 1$. Будем рассматривать эволюцию системы при различных значениях параметра затухания α поля E . При $\alpha \in (0.0; 0.03)$ фазы нейронов не синхронны. При $\alpha \in (0.03; 0.105)$ элементы ансамбля демонстрируют синхронную динамику. Поле E при этом периодическое, а переменные состояния практически всех нейронов совпадают (рис. 1). При больших значениях параметра α поле E становится модулированным, а нейроны не синхронны по переменной состояния. Амплитуда поля при переходе от синхронного к асинхронному режиму функционирования резко уменьшается, значение параметра синхронности μ при этом значительно увеличивается (рис. 1б).

Дальнейшее увеличение значения параметра затухания α сопровождается увеличением амплитуды поля E , параметр синхронности μ при этом принимает значения из отрезка $[0.65; 0.75]$ (рис. 1б). При увеличении значения параметра γ область значений параметра α , при котором ансамбль демонстрирует синхронную динамику, увеличивается (рис. 2).




Рис. 1. Случай синхронной динамики и переход к асинхронной динамике при $N = 100$, $\gamma = 1.03$, $g = 1.0$ и различных α , близких к нулю. (а) Значения локальных максимумов и минимумов поля E . Поле E периодическое, значения поля во всех локальных минимумах (максимумах) одинаковые при $\alpha \in (0.03; 0.105)$. Поле E сильно модулированное при $\alpha > 0.105$. (б) Значения параметра синхронности μ . μ близко к нулю в случае синхронной динамики. Возрастанию μ соответствует возникновение модуляций поля E и уменьшение его амплитуды

Зафиксируем параметр $\alpha = 0.05$. Будем рассматривать эволюцию системы при различных значениях параметра силы связи осцилляторов в ансамбле g . При g , принимающих значение, близкое к единице, элементы ансамбля синхронны, поле является периодическим, немодулированным. При увеличении параметра силы связи g происходит постепенное увеличение среднего значения поля E , поле при этом остается периодическим, элементы ансамбля синхронными. При приближении к критическому значению $g = 6.3$ среднее значение поля начинает резко увеличиваться, параметр синхронности μ увеличивается. При достижении параметром g критического значения, наступает ситуация, когда поле E становится возрастающим во времени, при этом импульс, прикладываемый к полю (получаемый при достижении фазы некоторого нейрона значения 2π), дает прибавку к полю больше, чем убывает значение состояния поля в межимпульсный интервал из-за диссипации (второе слагаемое в уравнении (5))

больше первого слагаемого, т.е. величина Q , а следовательно, и величина общего поля E растут со временем) при $g > 6.3$ (рис. 3). Т.е. диссипация не успевает компенсировать внешнее воздействие на поле. Рост общего поля E приводит к росту частоты вращений каждого нейрона, что в свою очередь ведет к дальнейшему росту поля.




Рис. 2. Карта режимов на плоскости параметров (γ, α) при $N = 100$, $g = 1.0$. Большему значению параметра γ соответствует более широкая область значений параметра диссипации α , при которых элементы ансамбля синхронны (область белого цвета соответствует синхронному режиму)

Данный эффект можно проиллюстрировать на простом примере. Рассмотрим одиночный фазовый элемент (уравнение (1) без $\sin \varphi_i$):

$$\dot{\varphi} = \gamma + gE, \quad (7)$$

и внешнее воздействие $E(t)$ пусть зависит от мгновенной частоты вращения $\dot{\varphi}$ и меняется в соответствии с уравнением

$$\dot{E} = -\alpha E + \dot{\varphi}. \quad (8)$$

Уравнения (7) и (8) перепишем в виде

$$\dot{E} = (g - \alpha)E + \gamma. \quad (9)$$

Из (9) следует, что при сильном внешнем сигнале ($g > \alpha$) величина $E(t)$ неограниченно растет (g в данном случае является аналогом параметра связи в модели (1), (2)). И, следовательно, происходит увеличение мгновенной частоты.




Рис. 3. Переход к асинхронному режиму в ансамбле. (а) Зависимость среднего значения поля E от силы связи g между элементами. (б) Значения параметра синхронности μ . $N = 100$, $\gamma = 1.01$, $\alpha = 0.05$

Выводы

В результате исследования динамики ансамбля было установлено существование двух динамических режимов функционирования его элементов: асинхронного, когда элементы распределены во времени на всем отрезке $[0; 2\pi]$, переменная состояния поля при этом периодическая, модулированная и имеет малую амплитуду; синхронного, где фазы нейронов ансамбля принимают близкие значения во времени, переменная поля периодическая, немодулированная и имеет более высокую амплитуду. Рассмотрена зависимость значения параметра синхронности от значений параметров диссипации и силы связи элементов ансамбля.

Список литературы

1. Pikovsky A., Rosenblum M., Kurths J. Synchronization: a Universal Concept in Nonlinear Sciences. Cambridge University Press, Cambridge, 2001.
2. Osipov G., Kurths J., Zhou Ch. Synchronization in oscillatory networks, Springer, Berlin, Heidelberg, 2007.
3. Mosekilde E., Maistrenko Yu., Postnov D., Chaotic synchronization. Application to living systems, World Scientific, Singapore, 2002.

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

ЛОКАЛЬНАЯ КРИВИЗНА И ТОЧНОСТЬ НЕЙРОСЕТЕВОЙ АППРОКСИМАЦИИ

Рассматривается задача повышения точности одномерной аппроксимации функций на нейросети с одним скрытым слоем. В качестве примера целевой функции используется многочлен Чебышева первого рода. Удаётся уменьшить среднеквадратичную ошибку аппроксимации более чем в сто раз. Это достигается путём замены в ряде мест обучения сети по методу обратного распространения ошибки на другие законы изменения параметров, а также выбора нелинейных функций нейроподобных элементов и настройки их свойств.

Ключевые слова: нейронные сети, аппроксимация, кривизна функции.

Введение

Успехи применения нейросетей для решения различных «интеллектуальных» задач привели к их широкому применению в различных областях. Вместе с этим сформировалось понимание, что обучение нейросетевых структур позволяет на основе большого числа примеров осуществлять аппроксимацию весьма сложных преобразований входных сигналов.

Настройка нейросетевых параметров направлена на уменьшение ошибки представления целевой функции, что можно рассматривать как повышение точности аппроксимации. Механизм, используемый для настройки параметра, – градиентный спуск, основанный на вычислении влияния изменения параметров сети на величину функции ошибки, которая, в свою очередь, вычисляется по разности значений целевой функции и преобразования, выполненного нейросетью.

Но очень быстро выяснилось, что прямое применение градиентного спуска (даже реализованного в виде алгоритма обратного распространения ошибки – ВРЕ [1]) не является оптимальным решением задачи настройки параметров нейросети. По существу, всё содержание книг по глубокому обучению нейросетей [например, 2, 3] можно свести к тому, что градиентный спуск следует применять не напрямую, а со всевозможными моментами, нормировками, регуляризациями и адаптивными алгоритмами.

И при всей эффективности совместного применения различных методов модификации «наивного» градиентного спуска, следует отметить, что направлены они не столько на достижение максимальной точности аппроксимации целевой функции преобразования, сколько на обеспечение сходимости процесса обучения и увеличение его скорости.

Это связано в первую очередь с тем, что, как правило, в глубоком обучении рассматриваются сложные задачи, для которых целевая функция явно не может быть определена, а задаётся большим массивом примеров.

Как путём вычислительных экспериментов, так и с информационно-теоретической точки зрения [4, 5] было показано, что лучшие результаты аппроксимации преобразований можно получить увеличивая (в разумных пределах) глубину (число скрытых слоёв) сети при сохранении общего числа элементов скрытых слоёв. Последние работы [6] показывают, что это связано с повышением вероятности формирования удачной конфигурации смежных слоёв и сравнивают этот процесс с лотереей. В нейросетях, построенных на вероятностных принципах, такой подход представляется естественным.

Альтернативой вероятностному подходу является исследование детерминированных преобразований на основе обеспечения наилучшего соответствия локальных свойств целевой функции и результатов её аппроксимации. В этом случае для исследования точности аппроксимации больше подходят явно заданные целевые функции небольшой размерности, в пределе – одномерные.




Рис. 1. Структура нейросети с одним скрытым слоем с 40 элементами

В данной работе для исследования различных методов аппроксимации на нейросети с одним скрытым слоем (рис. 1) в качестве целевой функции используется многочлен Чебышёва первого рода [7] на отрезке $[-1, 1]$ (рис. 2). В отличие от ставших классическими для глубокого обучения модификаций методов градиентного спуска, применяется полная замена ВРЕ на другие, не связанные с градиентным спуском, алгоритмы настройки параметров нейросети.




Рис. 2. Многочлен Чебышева первого типа (шестого порядка)

В заключение обсуждается возможность использования предлагаемых методов улучшения точности аппроксимации в многослойных нейросетях при решении сложных задач.

Два взгляда на нелинейность формальных нейронов

Важным свойством формальных нейронов является наличие в их структуре нелинейного преобразования. Вид преобразования может быть различным, но его присутствие в формальных нейронах многослойных структур обязательно.

Если формальные нейроны скрытого слоя сети, показанной на рис. 1, лишит нелинейного преобразования, то вне зависимости от числа нейронов скрытого слоя она сможет осуществлять только линейное преобразование типа

$$y = f_i(x) = wx + b, \quad (1)$$

где w и b – параметры, которые могут быть реализованы на выходном элементе. То есть в отсутствие нелинейных преобразований у скрытого слоя он не приносит никаких дополнительных свойств в преобразование $f_i(x)$. Причём данный вывод справедлив для любого числа скрытых слоёв.

Первый взгляд на нелинейность носит глобальный характер и выделяет тот факт, что только при наличии нелинейности в структуре формальных нейронов скрытых слоёв увеличение числа (как элементов, так и слоёв) позволяет аппроксимировать сложные нелинейные преобразования $f(x)$ общего вида.

Второй взгляд является локальным и состоит в том, что каждый элемент скрытого слоя представляет локальные свойства преобразования $f(x)$. Это выражается в том, что при наличии у формальных нейронов нелинейного преобразования $\varphi(w_i x + b_i)$ общий вид преобразования сети (рис. 1) выглядит так:

$$y = \sum_i w_i^{out} \varphi(w_i x + b_i) + b^{out}, \quad (2)$$

где w_i и b_i – параметры элементов скрытого слоя, а w_i^{out} и b^{out} – выходного элемента. Параметры w_i и b_i определяют локализацию нелинейности i -го элемента в пространстве X , а w_i^{out} – величину и знак вклада нелинейности i -го элемента в нелинейное преобразование $f(x)$ общего вида.

Локальный взгляд на значение нелинейностей элементов скрытого слоя указывает на необходимость распределения локализации нелинейно-

стей элементов скрытого слоя по области существования входного сигнала X .

Для преобразований с точечной локализацией нелинейности (типа ReLU, $\varphi(a_i) = \max(0, a_i)$, $a_i = w_i x + b_i$) локализация x_i нелинейности i -го элемента не вызывает сомнений и определяется из равенства

$$a_i = w_i x + b_i = 0 \rightarrow x_i = -b_i/w_i. \quad (3)$$

Преобразования с протяжённой нелинейностью типа логистического ($\varphi(a) = 1/(1 + e^{-a})$) или SoftPlus ($\varphi(a) = \log(1 + e^a)$) в разной мере вносят свой вклад в преобразование $f(x)$ общего вида во всей области существования входного сигнала X , но расположение точки, где этот вклад максимален, тоже легко локализуется и определяется по формуле, аналогичной (3).

«Вклад в нелинейность» – неформальное понятие, более строго будет говорить о величине 2-й производной или кривизны функции. Если ReLU и SoftPlus имеют единственную точку максимума этих параметров, то у логистической функции таких точек две и наибольший вклад в представление нелинейности преобразования $f(x)$ общего вида логистическая функция формального нейрона вносит в области между двумя этими точками.

Использование знаний о входном сигнале и преобразовании

Так же, как преимущества использования свёрточных (convolutional) и субдискретизационных (pooling) скрытых слоёв перед полносвязанными, основано на знании свойств входного сигнала и их важности для осуществляемого преобразования, так и понимание процесса аппроксимации функций может позволить выбирать более эффективные структуры и законы обучения для этой задачи.

Эффективно аппроксимировать конечным числом простых функций можно только относительно "хорошие" функции (ограниченные, гладкие) и на конечном пространстве входного сигнала X . Это значит, что свойства функции, в том числе кривизна, в окрестности большинства точек аргумента x меняются мало и приближённо могут рассматриваться как постоянные.

Требования к нейросети для выполнения аппроксимации

В сочетании с локальными взглядами на роль нелинейного преобразования в структуре формального нейрона постоянство свойств аппроксимируемых функций в окрестностях большинства точек в (ограниченном) пространстве существования входного сигнала X задаёт требования к свойствам элементов скрытого слоя нейросети (изображённой на рис. 1).

Пространство X необходимо разбить на области, нелинейные свойства каждой из которых представляют разные элементы скрытого слоя. Представление нелинейных свойств осуществляется настройкой параметров w_i

и b_i так, чтобы (в одномерном случае) $x_i = -b_i/w_i$ (3). Там, где нелинейные свойства целевой функции по пространству меняются быстрее, разбиение X на области должно быть более мелким для того, чтобы точнее проводить аппроксимацию.

Распространены наивные взгляды, что раз градиентный спуск позволяет уменьшить величину функции ошибки, которая, в свою очередь, количественно представляет ошибку аппроксимации, то простое применение алгоритма ВРЕ должно, как правило, приводить к распределению x_i по пространству X , соответствующему описанным в предыдущем абзаце требованиям.

К сожалению, это совсем не так. Случайно, конечно, может сложиться требуемое распределение x_i по пространству X . Но вероятность формирования такого распределения x_i по пространству X крайне мала. Это связано с тем, что алгоритм ВРЕ направлен только на уменьшение значения заданной функции ошибки (возможно, содержащей регуляризационные члены) и никак не настраивает распределение x_i по пространству X .

Важно не только правильно распределить области максимального проявления нелинейных свойств элементов скрытого слоя по пространству X , но и настроить их так, чтобы нелинейные свойства каждого из элементов в этих областях локально соответствовали нелинейным свойствам целевой функции.

Ниже излагаются алгоритмы, позволяющие настраивать элементы скрытого слоя согласно перечисленным требованиям. Они дополняют ВРЕ в том смысле, что работают вместе с ВРЕ на одной модели нейросети. Но ряд параметров сети настраивается по своим, отличным от ВРЕ, алгоритмам.

Для демонстрации эффекта от применения дополнительных алгоритмов при формировании нейросетевой аппроксимации целевой функции на одинаковых по структуре моделях нейросетей решается одинаковая задача аппроксимации целевой функции. Это позволяет сравнивать результаты обучения и делать выводы об эффективности последовательно добавляемых в сеть алгоритмов.

Решаемая задача и структура сети

Во всех примерах решается задача аппроксимации многочлена Чебышева шестого порядка на отрезке $[-1, 1]$ (рис. 2). Для получения оценки δ точности аппроксимации в процессе и по окончании обучения отрезок $[-1, 1]$ сканируется с шагом 0,05 и в 201 точке суммируются квадраты разности между целевой функцией $f(x)$ и выходом нейросети y :

$$\delta = \sum_{j=1}^{201} (f(x_j) - y_j)^2. \quad (4)$$

Во всех вычислительных экспериментах скрытый слой сети содержит по 40 элементов. Добавление алгоритмов может как уменьшать, так и уве-

личивать вычислительную сложность обучения и учёт затрат на вычисления усложняет сравнение различных моделей. Для повышения наглядности сравнений используются только графики изменения δ в процессе обучения, а сложность вычислений обсуждается качественно.

Параметры элементов сети задаются или случайно, или детерминированно, но хотя бы часть параметров в процессе обучения затем настраивается.

Обучение ведётся батчами, по 30 случайных x из отрезка $[-1, 1]$. Значение δ выводится на график после 100 батчей, каждый график содержит по 1000 значений δ . В ряде случаев обучение сходится значительно раньше, но для сравнения все модели проходят одинаковое число циклов обучения.

Поскольку как в процессе обучения одной сети, так и между разными сетями значения δ могут отличаться на несколько порядков, то для сравнимости результатов на графики выводится значение $\ln \delta$.

«Наивный» градиентный спуск

В качестве отправной точки для сравнения выбрано прямое применение алгоритма ВРЕ для обучения всех параметров единой структуры нейросети (рис. 1) с нелинейностью типа ReLU. Как отмечалось в [8], ВРЕ обеспечивает неуклонное снижение ошибки аппроксимации, но не отслеживает эффективность использования элементов скрытого слоя. Это выражается в том, что у некоторых элементов скрытого слоя точка проявления нелинейности x_i оказывается за областью существования x (вне отрезка $[-1, 1]$). У части других точки x_i «слипаются, то есть совпадают. Всё вместе это приводит к тому, что в результате обучения настройка параметров достигает локального минимума ошибки аппроксимации, далёкого от глобального, доступного для возможностей 40 элементов скрытого слоя. Ход процесса обучения отражён на рис. 3 кривой «наивный ВРЕ» (порядок описаний соответствует значениям справа).




Рис. 3. Графики обучения нейросетей с разными законами обучения

Применение метода Dropout [9] как средства регуляризации позволяет отчасти бороться с указанными явлениями. Хотя никакого overfitting при аппроксимации в данной задаче не наблюдается, выкидывание ряда эле-

ментов внутреннего слоя в процессе обучения позволяет «расцепить» значения их параметров и отчасти вернуть некоторые из точек x_i в отрезок

$[-1, 1]$. Это, естественно, повышает эффективность использования элементов скрытого слоя и даёт лучшие результаты обучения (кривая «Dropout» на рис. 3). При этом Dropout тоже не следит за распределением точек x_i на отрезке $[-1, 1]$, что оставляет полученные с его использованием результаты аппроксимации на достаточно низком уровне.

Жёсткое назначение локализации нелинейных свойств

Простейшим распределением точек x_i является их равномерное распределение по области определения x (отрезку $[-1, 1]$). Для достижения этой цели значения параметров w_i и b_i должны жёстко задаваться согласно формуле (3) и в дальнейшем не меняться. Такой подход позволяет получить лучшие результаты аппроксимации целевой функции и заметно сократить объём вычислений в процессе обучения.

Формула (3) даёт свободу для выбора значений w_i и b_i , ограничивая величину их отношения. Среди большого числа проверенных вариантов задания значений w_i и b_i наиболее успешным в смысле достижения высокой точности аппроксимации оказался способ, когда 40 точек x_i равномерно распределены по отрезку $[-1, 1]$, а выходная активность равна 1 в точке 1 или -1 (см. рис. 4)

Причины эффективности такого выбора понятны – точки x_i равномерно распределены по отрезку $[-1, 1]$ и активность элементов нормирована – не превосходит 1. Более подробное обсуждение данного метода улучшения точности аппроксимации выходит за рамки доклада, но он даёт результаты, превосходящие «наивное ВРЕ», улучшенное методом Dropout. Результаты обучения по описанному в данном пункте закону обозначены на рис. 3 «жёстко заданные».




Рис. 4. Вариант жёсткого задания активности элементов внутреннего слоя

Важным свойством описанного метода является его простота и низкие вычислительные затраты, что приводит не только к улучшению конечных результатов обучения, но и повышению начальной скорости обучения.

SoftPlus вместо ReLU

Точечное представление нелинейности в ReLU позволяет получить приближение целевой функции не лучше, чем первого порядка. Для получения более высоких порядков приближения необходимо использовать формальные нейроны, содержащие нелинейные преобразования обладающие конечной, но не нулевой кривизной.

Кривизна $k(x)$ одномерной функции $y(x)$ пропорциональна её второй производной, но зависит также от первой производной:

$$k(x) = |y''|/(\sqrt{1+y'^2})^3 \quad (5)$$

В отличие от ReLU, функция SoftPlus обладает конечной кривизной, которая максимальна в районе точки $a_i = w_i x + b_i = 0$ и быстро уменьшается по мере удаления от неё. Величину кривизны можно задавать параметром c_i :

$$\varphi(a_i) = \frac{1}{c_i} \log(1 + e^{c_i a_i}) \quad (6)$$

По мере роста c_i кривизна в точке x_i увеличивается и в пределе SoftPlus сколь угодно близко приближается к ReLU. Но это в теории. На практике c_i должно быть не слишком маленьким (чтобы избежать деления на 0) и не слишком большим (чтобы $e^{c_i a_i}$ не превысило максимальное представимое число), и в программе ставились явные ограничения на диапазон значений c_i .

Простая замена ReLU на SoftPlus приводит к следующему изменению картины выходной активности элементов скрытого слоя от значения x (рис. 5).

Даже если задавать c_i одинаковыми для всех элементов внутреннего слоя, то это приводит к улучшению аппроксимации целевой функции. Максимального улучшения удалось достичь при задании всех c_i равными 6,0. График обучения обозначен на рис. 3 как «SoftPlus».

Хотя по циклам обучения процесс идёт даже быстрее, чем с ReLU, и даёт лучший результат, объём вычислений значительно (порядка 10 раз) превосходит вариант с использованием ReLU. Это связано, в первую очередь, с вычислительной затратностью расчёта функции натурального логарифма.

Мягкое распределение локализации нелинейных свойств

Более тонкая настройка сети связана с учётом локальных свойств целевой функции, которым надо сопоставлять как плотность распределения точек x_i в разных местах отрезка $[-1, 1]$, так и локального задания кривизны нелинейной функции каждого элемента скрытого слоя. Начнём с плотности распределения.




Рис. 5. Жёсткое задание параметров элементов внутреннего слоя с активацией по функции SoftPlus – выходная активность элементов $o_i(X)$

Настройку плотности распределения точек x_i , которая локально определяется разностью значений x_i для соседних (по x) элементов скрытого слоя, можно осуществлять по-разному. Самым простым представляется использование метода к-средних для вычисления x_i и дальнейшего пересчёта x_i в параметры w_i и b_i . Начальные значения x_i задаются равномерно по отрезку $[-1, 1]$.

При подаче произвольного x среди элементов скрытого слоя находится такой, у которого x_i меньше всех отличается от x . После этого x_i изменяется на величину Δx_i , вычисляемую по формуле

$$\Delta x_i = \alpha \Delta y(x - x_i), \quad (7)$$

где Δy – ошибка аппроксимации в точке x , а α – малый параметр (выбирался равным 0,02).

Применение закона (7) позволяет более плотно собрать x_i в областях, где ошибка выше, и, наоборот, разредить их там где ошибка ниже. Результаты такого обучения приведены на рис. 6.




Рис. 6. Зависимость расстояния $l_i(x)$ между x_i элементов скрытого слоя и ошибкой аппроксимации $\Delta y(x)$ после обучения по закону (7)

На рис. 6 видно, что если до обучения среднее расстояние между x_i соседних элементов составляло 0,05, то после обучения в областях, где

ошибка аппроксимации больше, расстояние стало меньше 0,03, а там, где ошибка близка к нулю, превысило 0,06.

Более тонкая настройка позволила повысить точность аппроксимации – на рис. 3 кривая обучения обозначена как «к-средние». Для этого пришлось пожертвовать темпом обучения на начальных этапах. Вычислительная сложность по сравнению с предыдущим вариантом возросла на несколько процентов.

Локальная настройка параметров SoftPlus

Самой тонкой и самой затратной в данном докладе является настройка кривизны нелинейностей элементов скрытого слоя.

Сложность данной настройки определяется тем, что кривизна нейросетевого преобразования $y(x)$ определяется нелинейной суммой вкладов в кривизну всех элементов скрытого слоя. Поэтому, хотя настройке подвергается только c_i элемента с ближайшим к x значением x_i , направление изменения c_i выбирается по значению кривизны функции ошибки аппроксимации. Для выявления этого значения в элементы скрытого слоя вводятся дополнительные параметры w_i^c , настраиваемые аналогично w_i^{out} по ВРЕ, но не по целевой функции, а по изменяющейся по мере обучения функции ошибки аппроксимации.

Сложность и тонкость настройки приводят к её низкому темпу, но зато позволяет достичь наилучших (в данной работе) результатов аппроксимации, график кривой обучения на рис. 3 обозначен как «адаптивная кривизна».

Дальнейшее повышение точности аппроксимации

Все шесть отражённых на рис. 3 вариантов обучения могут быть на 10–30% улучшены в смысле повышения точности аппроксимации за счёт использования адаптивных алгоритмов изменения темпа обучения (rate), при которых темп обучения постепенно снижается практически до нуля.

Существенное повышение точности связано с многослойной иерархической организацией аппроксимации, когда представление целевой функции осуществляется более точным описанием характерных свойств похожих участков и их многократным воспроизведением с настраиваемыми параметрами.

Обобщение на многомерную аппроксимацию

Вопросы обобщения полученных результатов на многомерную аппроксимацию требуют дополнительных исследований. Исследованная структура модели ближе к полносвязанным скрытым слоям, и применение рассмотренных подходов для более сложных (например, свёрточных) скрытых слоёв требует существенного развития использованных идей. Но даже для полносвязанных слоёв обобщение на многомерную аппроксима-

цию возможно только в случае иерархической организации аппроксимации, которая позволяет локализовать нелинейные представления целевой функции.

Выводы

Сложность решаемых нейросетевыми методами прикладных задач не позволяет разработчикам эффективно исследовать методы повышения точности аппроксимаций выполняемых сетями преобразований. Рассмотрение же простых задач позволяет выявить методы улучшения аппроксимации.

Графики на рис. 3 показывают, насколько эффективны рассмотренные улучшения. Поскольку отображается натуральный логарифм ошибки аппроксимации, то изменение значения на 7 единиц (с 5 до -2) означает снижение квадратичной оценки ошибки аппроксимации в $e^7 \cong 1073$ раз или уменьшению средних отклонений в 32 раза.

Рассмотренные методы улучшения точности аппроксимации при дальнейшем их развитии могут быть использованы при решении задач многомерной аппроксимации на многослойных нейросетях.

Список литературы

1. Rumelhart D., Hinton G., and Williams R. Learning representations by back-propagating errors // Nature. N 323. 1986. P. 533–536.
2. Goodfellow I., Bengio Y., Courville Y. Deep learning // The MIT Press. 2016. (Русское издание: Гудфеллоу Я., Бенджио И., Курвилль А. Глубокое обучение / пер. с англ. А. А. Слинкина. 2-е изд., испр. Москва: ДМКПресс, 2018.)
3. Николенко С., Кадурин А., Архангельская Е. Глубокое обучение. Погружение в мир нейронных сетей. Санкт-Петербург : Питер, 2018.
4. Grohs, Ph., Perekrestenko D., Elbrachter D., Bolcskei H. Deep Neural Network Approximation Theory. <https://arxiv.org/pdf/1901.02220.pdf>
5. Feizi S., Javad H., Zhang J., Tse, D. Porcupine Neural Networks: Approximating Neural Network Landscapes // Advances in Neural Information Processing Systems. 2018. P. 4831–4841.
6. Morcos, A., Yu, H., Paganini, M., Tian, Y. One ticket to win them all: generalizing lottery ticket initializations across datasets and optimizers <https://arxiv.org/pdf/1906.02773.pdf>
7. Васильев Н., Зелевинский А. Многочлены Чебышёва и рекуррентные соотношения // Квант. № 1. 1982. С. 12–19.
8. Смолин В.С., Коваленко Е.И. От dropout к dropback // XX Международная научно-техническая конференция "Нейроинформатика-2018": Сборник научных трудов. В 2-х частях. Ч.2 . Москва : НИЯУ МИФИ. 2018. С. 64–75.
9. Strivastava, N. et al. A simple way to prevent Neural Networks from overfitting // Journal of Machine Learning Research. 2014. V. 15. N 1. P. 1920–1958.

А. А. МИКРЮКОВ, М. Е. МАЗУРОВ

Институт цифровой экономики и информационных технологий
Российский экономический университет им. Г.В. Плеханова, Москва
Mikrukov.aa@rea.ru

РЕШЕНИЕ ЗАДАЧИ КЛАССИФИКАЦИИ НА ОСНОВЕ КОМИТЕТА ИЗБИРАТЕЛЬНЫХ НЕЙРОСЕТЕЙ*

Рассмотрен подход к совершенствованию методов решения задач классификации на основе нейросетевых комитетов (ансамблей). Для построения нейросетевого комитета предложен новый класс нейросетей, получивших название избирательных нейросетей. Научная новизна работы заключается в повышении качества решения задачи классификации комитетом избирательных нейросетей. Предложенный подход может найти применение в подсистемах поддержки принятия решений ситуационного центра информационной безопасности.

Ключевые слова: избирательная нейросеть, коллективный классификатор, нейросетевой ансамбль, комитет нейросетей.

Введение

В настоящее время широкое распространение для решения задач моделирования разнообразных систем, которые относятся к классу трудно формализуемых и слабоструктурированных, получили нейросетевые подходы, в частности применение ансамблей нейронных сетей, которые являются примером коллективного решения задач.

Качество решения конкретной задачи (интеллектуального анализа данных, прогнозирования, распознавания образов, классификации и др.) может быть существенно повышено с использованием ансамблей нейросетей, в которых предполагается формирование и обучение конечного множества нейросетей, результаты решения которых учитываются в общем решении. При этом индивидуальные решения согласовываются таким образом, чтобы общее итоговое решение было наилучшим.

Как известно, одной из фундаментальных проблем совершенствования функционирования ансамбля нейросетей в составе подсистем поддержки принятия решений информационно-аналитических систем (ИАС) ситуа-

* Работа выполнена при финансовой поддержке РФФИ (проекты №№ 18-07-00918А, 19-07-01137).

ционных центров с точки зрения повышения их точности и достоверности является генерация разнообразия ансамбля (различия индивидуальных моделей) [1]. Агрегация схожих моделей в ансамбле не может привести к существенному повышению качества решения задачи.

Для разрешения указанного противоречия предложено использовать подходы на основе коллектива (ансамбля) нейросетей, для построения которых применяются новый класс искусственных нейронов, так называемых избирательных нейронов, отличающихся от классических нейронов более эффективным способом обработки входной информации, приближенным к биологическому нейрону [2]. Избирательные нейроны в силу особенностей их построения, обучения и функционирования обеспечивают, с одной стороны, построение более эффективных нейросетей для решения поставленных задач, а с другой стороны, большее разнообразие нейросетей в ансамбле. Рассмотрим особенности построения и функционирования избирательных нейросетей.

Особенности построения и функционирования избирательных нейросетей

Избирательные сети строятся на основе избирательных нейронов, модель которых приближена к модели биологического нейрона. Обучение избирательной нейросети осуществляется не за счет изменения весовых коэффициентов синаптических связей, а за счет изменения количества и качества тормозных и возбуждающих дендритов (передатчиков сигналов), на основе которых строятся избирательные нейроны [2].

Математически искусственный нейрон обычно представляется как нелинейная функция от линейной комбинации сигналов с ограниченным количеством входов. Результат работы функции направляется на единственный выход нейрона и далее на вход нейрона из следующего слоя. Каналы связи, по которым поступают сигналы, характеризуются весами. Задача обучения сети состоит в подборе таких весов для каждой связи, которые бы минимизировали итоговое значение ошибки выходного значения.

На рис. 1 представлена схема нейрона МакКаллока–Питтса, который является базовым элементом большинства классических нейронных сетей, имеющих прикладное значение [3].

На рис. 1 приняты обозначения $x = (x_1, \dots, x_n)$, $w = (w_1, \dots, w_n)$. Рассмотрим математическую модель искусственного нейрона. После прохождения порогового устройства и преобразования пороговой функцией $F(S)$ получаем выходной ответ, равный

$$y = F(S) = F\left(\sum_{i=1}^N w_i x_i - \theta\right) = F(\mathbf{w}, \mathbf{x} - \theta), \quad (1)$$

где $x = (x_1, \dots, x_N)$, $w = (w_1, \dots, w_N)$, (w, x) – скалярное произведение векторов w, x ; N – число входов нейрона; θ – порог возбуждения.




Рис. 1. Схема нейрона МакКаллока–Питтса.

Обозначения:

$x_1, x_2, \dots, x_8$ – входные сигналы;

КС – каналы связи,

Σ – сумматор;

W – веса синаптических связей;

Π – функция произведения $x_i * w_i$;

F – нелинейная пороговая функция;

Y – выходной сигнал

Однако у классических типов нейронных сетей имеется серьезный недостаток – неустойчивость к переобучению. Если количество весов в сети будет велико, то операция по суммированию их линейной комбинации будет крайне вычислительно трудоемкой, и с большой вероятностью возникнет эффект переобучения, когда сеть с крайне высокой точностью распознает образы на обучающем множестве, но при этом показывает достаточно большой процент ошибки на тестовом множестве входных данных.

Таким образом, недостатки классических нейросетей являются следствием использования весовых коэффициентов синаптических связей. Действительно, в биологическом нейроне не существует никакой весовой градации – это искусственный прием. Решение основных задач обработки входного сигнала достигается изменением конфигурации кластеризации и числа дендритов на входе биологического нейрона [4, 5].

Проведенный анализ показал, что, по аналогии с биологическими механизмами, целесообразно использовать нейронную сеть, включающую в своем составе нейроны, получившие название избирательные нейроны, с

управляемой кластеризацией входных каналов (синапсов) по количеству, а далее кластеризацию каналов по качеству (возбуждающие или тормозящие). В качестве эффективного классификатора образов предложено использовать нейронную сеть на основе избирательных нейронов. Избирательный нейрон не имеет весовых коэффициентов синаптических связей и приближен по свойствам к своему биологическому аналогу (рис. 2).

Формирование кластера включает в себя блокирование неинформативных каналов связи, не проводящих возбуждающих или тормозящих сигналов [4–7]. Таким образом, после обучения каждый нейрон имеет кластер с индивидуальной передаточной характеристикой, где заблокированы некоторые входы для сигналов (заблокированные входы отмечены треугольниками), которые заведомо отличаются от обучающей кодовой комбинации.




Рис. 2. Схема избирательного нейрона.

Обозначения:

$x_1, x_2, \dots, x_9$ – входные сигналы в виде бинарного кода;

K – кластер каналов связи, сформированный в соответствии с бинарным кодом на входе;

Σ – сумматор;

F – нелинейная пороговая функция;

y – выходной сигнал

Отличительной особенностью избирательного нейрона является наличие кластера, который формируют из совокупности внутренних каналов связи. Формирование кластера осуществляется в соответствии со специфическими свойствами входного сигнала; кластер связан с сумматором, после чего производится нелинейное пороговое преобразование сигнала, которое используют как выходной сигнал.

С учетом недостатков известного однослойного перцептрона предложен избирательный однослойный перцептрон на основе избирательных нейронов [6]. Эффективный способ получения избирательности в системе

из n нейронов реализован практически. Блок-схема избирательного перцептрона представлена на рис. 3.




Рис. 3. Структура избирательного однослойного перцептрона на основе избирательных нейронов.

Обозначения:

K_i – сформированные кластеры каналов связи;

Σ – сумматор;

F – нелинейная функция;

Y_i – выходной сигнал

В однослойном избирательном перцептроне в каждом избирательном нейроне формируются кластеры специализированных каналов связи – дендритов, настроенные на соответствующие характеристические векторы входных сигналов. Треугольниками отмечены заблокированные каналы связи из числа входных, не являющихся существенными характеристическими векторами для объекта на входе перцептрона.

Благодаря особенностям своего построения и функционирования избирательная нейросеть обеспечивает:

- избирательное распознавание входных сигналов без использования взвешивания их синаптических связей;
- возможность кодирования входного сигнала определенного типа номером канала или номером регистрирующего нейрона;
- сжатие входной информации, благодаря сохранению только той информации об объектах, которая попадает в заданный канал или регистрирующий нейрон;
- повышение быстродействия функционирования;

- повышение надежности распознавания объектов при их большом количестве;

- значительно большую степень адекватности избирательного нейрона биологическому однослойному перцептрону.

Для повышения качества решения задачи классификации предложен подход к реализации ассоциативной машины (нейросетевого ансамбля) на основе рассмотренных избирательных нейросетей.

Нейросетевые ансамбли на основе избирательных нейросетей

Нейросетевые модели, применяемые для решения задач классификации в подсистемах поддержки принятия решений ИАС, обладают рядом особенностей и преимуществ. Они являются адаптивными самообучающимися системами, которые динамически промоделировать достаточно трудно, а зачастую просто невозможно, т.к. они часто содержат значительный массив скрытых, неконтролируемых, неполных и зашумленных параметров и взаимных связей между ними. Их применение позволяет решать задачи, которые трудно или невозможно решить традиционными методами в силу отсутствия формализованных математических описаний процессов функционирования объекта исследования. Нейросетевые модели обладают ассоциативной памятью и в процессе работы накапливают и обобщают информацию, от чего эффективность их со временем возрастает. Их использование базируется на обучении нейросети для извлечения информации из опытных данных, что обеспечивает объективность результатов и повышает их надежность и достоверность [8].

При построении ансамбля нейросетей одновременно используют конечное множество предварительно обученных нейросетей, выходные сигналы которых комбинируются в объединенную оценку, превосходящую по качеству результаты, полученные с помощью локальных сетей, входящих в ансамбли (рис. 4).




Рис. 4 Ансамбль нейросетей

Ансамблем $\bar{H}(x)$ моделей $\bar{h}_i(x)$ ($i=1,2, \dots, N$) называется композиция алгоритмических операторов $h_i: R^d \rightarrow R$ и корректирующей операции

$F: R^N \rightarrow R$, в которой множеству оценок $\bar{h}_1(x), \bar{h}_2(x), \dots, \bar{h}_N(x)$ ставится в соответствие итоговая оценка $\bar{H}(x)$ [8]:

$$\bar{H}(x) = F(\bar{h}_1(x), \bar{h}_2(x), \dots, \bar{h}_N(x)).$$

Как известно, фундаментальной задачей при построении ансамблей является генерация разнообразия ансамбля (или различия индивидуальных моделей) [9, 10].

Очевидно, что агрегация схожих моделей в ансамбле не может привести к существенному повышению качества решения задачи. Проблема генерации разнообразия заключается в том, что индивидуальные модели классических нейросетей на основе нейрона МакКаллока–Питтса, обучаются для решения одной задачи по одной обучающей выборке и вследствие этого обычно достаточно сильно коррелированы, что существенно сказывается на точности получаемого решения.

Анализ существующих подходов к решению задачи агрегирования результатов функционирования типовых нейросетевых классификаторов показал, что они не всегда обеспечивают необходимое качество принятия итогового решения (точность и обоснованность).

К наиболее существенным недостаткам таких классификаторов относятся [11]:

- зависимость конечного результата от достоверности определения коэффициентов компетентности, что может привести к некорректному результату;

- часто обучающая выборка содержит шумовые выбросы, приводящие к увеличению вероятности ошибочных решений частными классификаторами, т.к. попытка обучающего алгоритма настроиться на шум ухудшает аппроксимирующие возможности сети;

- необходимость использования большого количества примеров обучающей выборки для успешной реализации алгоритма;

- архитектура нейросетевого ансамбля зачастую является избыточной, что не способствует увеличению точности решения задач классификации и приводит к существенному увеличению требуемого вычислительного ресурса.

Влияние указанных недостатков может быть существенно снижено путем использования нейросетевого ансамбля на основе избирательных нейросетей. На основе разработанной модели избирательного нейросетевого ансамбля, представляющего совокупность нейросетей, состоящих из избирательных однослойных перцептронов, было проведено моделирование процесса классификации сетевых атак на информационную систему корпорации. Из технологий, обеспечивающих эффективное проецирование решений частных классификаторов на целевое пространство, приме-

нялся метод многоярусного обобщения (использует двухступенчатую процедуру формирования решений классификаторов с нелинейной комбинацией отдельных решений), имеющий различные модификации [10, 12].

Проверка предложенного подхода проводилась с использованием тестовых данных из репозитория [13]. В качестве исходных данных использовались следующие параметры сетевого трафика:

1. Сетевая служба получателя (http, ssh, rdp, https).
2. Длительность сессии в секундах.
3. Количество пакетов в сессии.
4. Количество запросов в сессии.
5. Количество ответов в сессии.
6. Количество запросов с подозрительными последовательностями символов.
7. Количество попыток авторизации в минуту.
8. Количество ошибочных пакетов в сессии.
9. Состояние соединения (active, established, closed).
10. Идентичность портов отправителя и получателя (идентичные/различные).

Результатом работы обученного нейросетевого ансамбля является классификация сетевого трафика на 2 класса (легитимный трафик или подозрительный трафик). Для проведения сравнительного эксперимента использовались двухслойные нейросети прямого распространения. Результаты вычислительного эксперимента показали увеличение точности решения задачи классификации на основе нейросетевых ансамблей в среднем на 8-12%, а качество разнообразия (под разнообразием понимается степень некоррелированности ошибок членов комитета, существенное влияние которой подтверждается, в том числе экспериментально) моделей избирательных нейросетей, рассчитанное как разница между квадратичной ошибкой ансамбля и средней ошибкой индивидуальных моделей избирательных нейросетей, улучшилось на 10–14%. При этом существенно сокращен объем (трудоемкость) вычислений при обучении избирательных нейросетей классификатора.

Заключение

Проведенные исследования показали, что применение нового класса нейросетей, основанных на избирательных нейронах, для построения нейросетевых ансамблей в подсистемах поддержки принятия решений информационно-аналитических систем позволяет существенно повысить качество (точность и достоверность) принятия решений ансамблем нейросетей. Показано, что избирательный нейросетевой ансамбль являет-

ся более эффективным средством классификации по сравнению с классическим нейросетевым ансамблем.

Ключевым отличием избирательного нейрона от классического нейрона МакКаллока–Питтса является то, что избирательный нейрон не имеет весовых коэффициентов синаптических связей и приближен по свойствам к своему биологическому аналогу. В основе функционирования избирательных нейросетей используется управляемая кластеризация входных каналов, индивидуальная для каждого нейрона, что в свою очередь обеспечивает качество их работы.

Применение избирательных нейросетевых классификаторов в составе ассоциативных машин позволяет повысить быстродействие их проектирования, скорость вычислений, а также надежности функционирования.

Список литературы

1. Kuncheva L.I. Combining Pattern Classifiers: Methods and algorithms. John Wiley & Sons, Hoboken, NJ, 2004.
2. Мазуров М.Е. Импульсный нейрон, близкий к реальному. Патент на изобретение № 2598298. 30.08.2016.
3. Александров Ю.И., Анохин К.В., Соколов Е.Н., Греченко Т.Н. и др. Нейрон. Обработка сигналов. Пластичность. Моделирование. Фундаментальное руководство. Тюмень : Изд-во Тюменского государственного университета. 2008. 548 с.
4. Мазуров М.Е. Нейрон, моделирующий свойства реального нейрона. Патент на изобретение № 2597495. 22.08.2016.
5. Мазуров М.Е. Избирательные нейронные сети для распознавания сложных объектов. В: Математическая биология и биоинформатика: труды VI Международная конф. Москва: МАКС Пресс. 2016.
6. Мазуров М.Е. Однослойный перцептрон на основе избирательных нейронов. Патент на изобретение № 2597497. 22.08.2016.
7. Мазуров М.Е. Однослойный перцептрон, моделирующий свойства реального перцептрона. Патент на изобретение № 2597496. 22.08.2016.
8. Морозов А.А., Клименко В.П., Ляхов А.Л., Алешин С.П. Состояние и перспективы нейросетевого моделирования СППР в сложных социотехнических системах // Математические машины и системы. 2010. № 1.
9. Журавлев Ю.И. Об алгебраическом подходе к решению задач распознавания и классификации // Проблемы кибернетики. 1978. Т. 33.
10. Zhou Z.-H. Ensemble Methods: Foundations and algorithms. Chapman & Hall/Crc Machine Learning & Pattern Recognition. 2012.
11. Бова В.В., Дуккарт А.Н. Применение искусственных нейронных сетей для коллективного решения интеллектуальных задач. Проблемы представления знаний в интегрированных системах поддержки управленческих решений // Известия ЮФУ. Технические науки. 2010. № 7 (108). С. 131–138.
12. Wolpert D.H. Stacked generalization // Neural Networks. 1992. N 5. P. 241–259.
13. Frank A., Asuncion A. UCL Machine Learning Repository. University of California, School of Information and Computer Science, Irvine, CA, 2010. [Электронный ресурс] URL: <http://arhive.ics.uci.edu/ml> (дата обращения 17.04.2019).

А. В. ЧЕРНЫШОВ, С. А. ЛОБОВ

Нижегородский государственный университет им. Н.И. Лобачевского
lobov@neuro.nnov.ru

ХЕББОВСКОЕ И КОНКУРЕНТНОЕ ОБУЧЕНИЕ В ИМПУЛЬСНЫХ НЕЙРОНАХ*

Исследуется возможность хеббовского и конкурентного типов обучения в импульсных нейронах в задаче временного и частотного кодирования информации. Под кодированием подразумевается достигаемая в результате обучения селективность нейрона к обучаемому паттерну. Показано, что применения хеббовского обучения в виде парного или триплетного правила STDP достаточно для реализации временного, но не для частотного кодирования. Для обеспечения селективности синапсов при частотном кодировании необходима синаптическая конкуренция, обеспечивающая депрессию менее используемых синапсов. Данный вид конкуренции в работе реализуется путем ввода функции забывания, пропорциональной активности нейрона. Показано, что совместное использование Хеббовского обучения в виде триплетного правила STDP и синаптического забывания позволяет осуществить частотное кодирование.

Ключевые слова: временное кодирование, частотное кодирование, синаптическая конкуренция, STDP, парное правило STDP, триплетное правило STDP.

Введение

Искусственные нейронные сети, основанные на формальных нейронах (ФНС), широко применяются в задачах аппроксимации, классификации и кластеризации данных [1]. Формальный нейрон, первоначально предложенный Мак-Каллоком и Питтсом [2], представляет собой взвешенный сумматор входных данных с выходной функцией активации. Максимальное упрощение единичного нейрона позволило разработать ряд эффективных процедур обучения, однако формальный нейрон не является динамической моделью живого нейрона и не может быть использован для решения ряда нейровычислительных задач, основанных, например, на временном кодировании и эффектах синхронизации.

* Данная работа выполнена при поддержке Министерства образования и науки Российской Федерации, проект № 14.Y26.31.0022

Импульсные нейронные сети (ИНС) являются относительно новой парадигмой нейронных вычислений. Импульсный нейрон представляет собой динамическую систему, в которой нервный импульс генерируется при достижении порогового уровня. При этом биологически релевантные модели нейронов предполагают наличие динамического порога возбуждения, определяемого предшествующей активностью [3]. Исследователи отмечают большие потенциальные возможности ИНС [4], но при этом количество реализованных практических приложений на основе ИНС остается крайне ограниченным.

Функционал работы нейронной сети обеспечивается обучением, то есть настройкой ее свободных параметров – весов связей нейронов. Для формальных нейронов предложен ряд базовых правил обучения, в частности хеббовское обучение [1], заключающееся в увеличении веса связи пропорционально входному сигналу, поступающему по данной связи, и выходной активности:

$$\Delta w_{ij} = \eta x_j y_i, \quad (1)$$

где Δw_{ij} – изменение весового коэффициента связи между нейронами j и i , η – константа обучения, x_j – выходная активность нейрона j (входной сигнал для нейрона i), y_i – выходная активность нейрона i . Уравнение (1) в чистом виде не применяется, так как приводит к неограниченному росту весов. Данный недостаток можно устранить, в частности, введя слагаемое забывания, зависящее от выходной активности нейрона и веса входной связи [1]:

$$\Delta w_{ij} = \eta x_j y_i - F(y_i) w_{ij}. \quad (2)$$

Если в сети нейронов организовано «соревнование», например, в виде правила «победитель забирает все» и соблюдены некоторые ограничения [1], то (2) можно преобразовать к правилу конкурентного обучения, широко применяемое в ФНС в задачах обучения без учителя:

$$\Delta w_{ij} = \begin{cases} \eta(x_j - w_{ij}), & \text{если нейрон } i \text{ побеждает в соревновании } (y_i = 1), \\ 0, & \text{если нейрон } i \text{ проигрывает в соревновании } (y_i = 0). \end{cases} \quad (3)$$

В отличие от ФНС в ИНС можно применять экспериментально подтвержденный вариант хеббовского обучения – STDP (англ. Spike Timing Dependent Plasticity – пластичность, зависящая от соотношения времени импульсов). STDP усиливает связь между двумя нейронами, если постсинаптический нейрон генерирует импульс после пресинаптического и ослабляет в обратном случае [3]. Важно отметить, что данному типу пластичности присущи элементы синаптической конкуренции, ставящей

«успешность» синапса в зависимость от времени импульсов, которые передаются им [5].

Цель данной работы заключалась в исследовании возможности решения нейроном с STDP-зависимыми связями задачи временного и частотного кодирования. Под кодированием подразумевалось достижение такого распределения весов входных связей, которое бы зависело от характеристики импульсов (время или частота), поступающих по этим связям в составе повторяющегося комплексного паттерна. О качестве обучения судили по сравнению активности нейрона при его стимуляции обучающим и незнакомым паттерном.

Методика исследования

В исследовании использовалась модель импульсного нейрона, предложенная Евгением Ижикевичем [6]. STDP было реализовано с помощью локальных переменных $y_i(t)$, увеличивающих свое значение на единицу при генерации импульса в момент времени t_i^{sp} и экспоненциально затухающих с характерным временем τ [3]:

$$\frac{dy_i}{dt} = -\frac{y_i}{\tau} + \delta(t - t_i^{sp}), \quad (4)$$

где $\delta()$ – дельта-функция Дирака.

Изменение веса в «классическом» или парном варианте STDP рассчитывалось следующим образом:

$$\frac{dw_{ij}}{dt} = F_+(w_{ij})y_j(t)\delta(t - t_i^{sp}) - F_-(w_{ij})y_i(t)\delta(t - t_j^{sp}). \quad (5)$$

При этом зависимость от веса определялась мультипликативным правилом:

$$F_+(w_{ij}) = \lambda(1 - w_{ij}), F_-(w_{ij}) = \lambda\alpha w_{ij}, \quad (6)$$

где $\lambda = 0.001$ – скорость обучения и $\alpha = 5$ – коэффициент асимметрии.

Так как в исследовании предполагалось реализовать частотное кодирование, также использовалось триплетное правило, характеризующееся частотной зависимостью [3]. В отличие от парного правила в триплетном используются две локальные переменные – «быстрая» и «медленная» с разными характерными временами затухания τ_1 и τ_2 , при этом динамика этих переменных также представлена выражением (4). Изменение веса в положительную сторону в случае генерации импульса на постсинаптическом нейроне пропорционально не только значению быстрой переменной $y_j^1(t)$ на пресинапсе (как в случае с парной STDP), но и медленной y_i^2 на постсинапсе:

$$\frac{dw_{ij}}{dt} = F_+(w_{ij})y_j^1(t)y_i^2(t)\delta(t - t_i^{sp}) \quad (7)$$

При этом изменение веса в отрицательную сторону рассчитывалось так же, как и в случае парной STDP, значения параметров использовались следующие: $\lambda = 0.001$, $\alpha = 1$, $\tau = 10$ мс, $\tau_1 = 10$ мс, $\tau_2 = 100$ мс.

Временное и частотное кодирование реализовывалось по схеме (рис. 1), согласно которой каждый из десяти пресинаптических нейронов кодировал время либо частоту импульсов во входном повторяющемся паттерне, предъявляемом постсинаптическому нейрону в процессе обучения. Обучение длилось 1000 с модельного времени.




Рис. 1. Схема реализации временного (А) и частотного (Б) кодирования. S_{1-10} – стимуляторы, N_{1-10} – пресинаптические нейроны, N_p – постсинаптический нейрон, t_j – время начала стимулирующего импульса для нейрона N_j , $\Delta t = t_{j+1} - t_j$ – время между импульсами. F_{1-10} – частоты стимуляции пресинаптических нейронов

При временном кодировании паттерн стимуляции задавался в виде последовательности импульсов, задержка между которыми Δt составляла в разных вариантах численного эксперимента 1, 2, 5, 10 и 20 мс. Частота следования комплексного паттерна составляла 1 Гц.

При частотном кодировании параметры стимуляции пресинаптических нейронов подбирались таким образом, чтобы они генерировали импульсы со средними частотами 0.1, 0.2, 0.5, 1, 2, 3, 6, 12, 25 и 50 Гц.

Для оценки качества обучения в обеих схемах использовался паттерн, использующийся при обучении, и «незнакомый» паттерн. Для его генерации во временной схеме кодирования последовательность стимулов была обращена – поочередно стимулировались пресинаптические нейроны с десятого по первый. Время между импульсами Δt было выбрано равным 10 мс. В схеме частотного кодирования обращалась частота генерации импульсов – первый нейрон генерировал импульсы с частотой 50 Гц, последний – 0.1 Гц.

Результаты и обсуждение

В схеме временного кодирования информация представлена в последовательности импульсов входного паттерна. В результате обучения постсинаптического нейрона ожидалось получить распределение весов входных связей, зависящее от времени импульсов в составе обучаемого паттерна. Действительно, при воздействии ритмической стимуляции нейрона с STDP (как с парным, так и триплетным правилом) повторяющимся паттерном обнаружена зависимость между весовыми коэффициентами связей и порядковыми номерами импульсов, приходящих по этим синапсам в составе паттерна (рис. 2А). Численные эксперименты проводились с разной величиной задержки импульсов друг относительно друга – от 1 до 10 мс, соответственно продолжительность всего комплексного паттерна составляла от 10 до 100 мс. При величине задержки до 5 мс усиливались связи, соответствующие начальному времени паттерна, причем больше всего потенцировалась связь, по которой приходил первый импульс. При этом количество «сильных» связей ограничивалось двумя-тремя, что можно объяснить свойством рефрактерности нейронов. При относительно коротких временах между элементами паттерна каждый последующий импульс приходит в момент сниженной чувствительности нейрона. В результате в ответ на стимул импульса на обучаемом нейроне не наблюдается и вес такой связи уменьшается. При увеличении продолжительности комплексного паттерна нейрон успевает восстановить возбудимость в течение экспозиции одного паттерна, что приводит к усилению связей, соответствующих середине паттерна (рис. 3А).




Рис. 2. Результаты реализации временного кодирования при времени между импульсами $\Delta t = 1$ мс: А) Зависимость значений весовых коэффициентов нейронных связей от порядкового номера связи (импульса в паттерне). Б) Активность постсинаптического нейрона после обучения при предъявлении выученного и незнакомого паттерна

В качестве критерия успешности обучения можно рассматривать селективную активацию нейрона при подаче на него «выученного» паттерна. Так, при выраженной зависимости весов от номера синапса (рис. 2А) как в случае парного, так и триплетного правила STDP нейрон демонстрирует высокую активность при предъявлении выученного паттерна и низкую в ответ на незнакомый паттерн (рис. 2Б). В случае больших задержек между стимулами и чередующейся силе связей (рис. 3А) нейрон практически не различает эти паттерны (рис. 3Б).




Рис. 3. Результаты реализации временного кодирования при времени между импульсами $\Delta t = 10$ мс. Обозначения как на рис. 2

Таким образом, одиночный нейрон при временной схеме кодирования потенциально может быть селективным только к импульсам в начальной фазе паттерна. Данный эффект согласуется с опубликованными данными и в общем случае для кодирования сложных и длительных временных паттернов необходима сеть нейронов с реализацией нейронной конкуренции и временных задержек [7]. Селективностью к начальной фазе паттерна можно также объяснить центробежное (относительно стимула) распределение связей при STDP-опосредованной сетевой синхронизации моно-слойной сети [8].

Попытка реализовать частотное кодирование с помощью STDP не дала ожидаемой картины зависимости распределения весовых коэффициентов от частоты стимулов (рис. 4А).

Очевидно, в случае парного правила STDP это связано с тем, что стимуляция постсинаптического нейрона пресинаптическими происходит параллельно. При этом постсинаптический нейрон имеет конечное значение времени возбудимости, и постоянная стимуляция частотным паттерном приводит к «колебаниям рефрактерности» на постсинапсе. Во время

возбудимого состояния постсинаптического нейрона входящие импульсы вне зависимости от их частоты способны вызвать ответные импульсы, что соответствует ситуации “пресинапс-постсинапс”, ведущей по правилу STDP к усилению связей. Остальные импульсы всех частот попадают на период рефрактерности, что соответствует ситуации “постсинапс-пресинапс”, ведущей по правилу STDP к ослаблению связей. В итоге вне зависимости от частоты передаваемых импульсов веса всех связей усредняются.




Рис. 4. Результаты реализации частотного кодирования при использовании парного (STDP) и триплетного (tSTDP) правила: А) Зависимость значений весовых коэффициентов нейронных связей от частоты импульсов пресинаптических нейронов. Б) Активность постсинаптического нейрона после обучения при предъявлении выученного и незнакомого паттерна

В случае с триплетным правилом STDP полученные негативные результаты могут быть объяснены следующим образом: высокочастотная составляющая стимулирующего паттерна задает и поддерживает высокое текущее значение медленной переменной y_i^2 . Увеличение веса связи пропорционально произведению текущих значений быстрой переменной на пресинапсе и медленной на постсинапсе. Так как значение медленной переменной высокое, это приводит к увеличению всех весов связей. Триплетное правило STDP у импульсных нейронов более всего соответствует хеббовскому обучению для формальных нейронов и соответственно имеет тот же недостаток – неограниченный рост весов. Точнее, при применении мультипликативного правила (6) вес ограничен единицей, но возникает проблема отсутствия селективности. В результате нейрон не может различить паттерны (рис. 4Б).

Решением данной проблемы является реализация синаптической конкуренции. Так же, как и в случае с формальными нейронами, в импульсном нейроне ее можно реализовать путем ввода функции забывания для вход-

ных синапсов («деградация» синапсов), пропорциональной активности нейрона:

$$\frac{dw_{ij}}{dt} = -\frac{w_{ij}y_i}{\tau_f}, \quad (9)$$

где w_{ij} – вес связи с j -ым нейроном; τ_f – характерное время деградации синапса; y_i – выходной сигнал i -го нейрона:

$$\frac{dy_i}{dt} = \delta(t - t_i^{sp}) - \frac{y_i}{\tau_o}, \quad (10)$$

где τ_i^{sp} – момент генерации импульса; τ_o – характерное время усреднения активности.

В итоге при совместном использовании триплетного правила STDP и синаптической деградации с параметрами $\tau_f = 10$ мс, $\tau_o = 100$ мс удалось получить выраженную зависимость веса синапсов от входной частоты пресинаптических импульсов (рис. 5А). Необходимо отметить, что зависимость носит ярко выраженный сигмоидный характер. Тестирование селективности показало, что активность постсинаптического нейрона при предъявлении выученного паттерна намного выше, чем в ответ на незнакомый (рис. 5Б).




Рис. 5. Результаты реализации частотного кодирования при использовании триплетного правила STDP и функции забывания (“деградация” синапса). Обозначения как на рис. 4

Необходимо отметить, что в данной работе не исследовалось качество селективности, достигаемой в результате обучения. В случае реализации как временного, так и частотного кодирования для тестирования селективности применялся паттерн, диаметрально противоположный обучаемому. Недавно была предложена концепция многомерного нейрона, согласно которой селективность нейрона нелинейно зависит от количества входных синапсов. Показано, что при количестве синапсов более 20 для формального нейрона теоретически достижимая селективность может приближаться к 100% [9]. При использовании 10 синапсов, как в текущей работе, теоретическая селективность составляет примерно 50%, что говорит о том, что в пространстве входных паттернов даже идеально обучен-

ный нейрон около половины паттернов будет классифицировать как «свой». Очевидно, в случае импульсных нейронов можно ожидать похожей закономерности и ее исследование – предмет будущей работы.

Выводы

Таким образом, в ходе работы показана возможность реализации хеббовского и конкурентного типов обучения в импульсных нейронах в задаче временного и частотного кодирования информации.

Применения Хеббовского обучения в виде парного или триплетного правила STDP оказалось достаточным для реализации временного кодирования. При этом нейрон чувствителен только к импульсам в начальной фазе паттерна. Для кодирования сложных и длительных временных паттернов необходима сеть нейронов с реализацией нейронной конкуренции и временных задержек.

Хеббовского обучения оказалось недостаточно для реализации частотного кодирования. Для обеспечения селективности необходима синаптическая конкуренция, обеспечивающая депрессию менее используемых синапсов. Данный вид конкуренции можно реализовать путем ввода функции забывания для входных синапсов, пропорциональной активности нейрона. Совместное использование хеббовского обучения в виде триплетного правила STDP и синаптического забывания позволяет осуществить частотное кодирование.

Список литературы

1. Haykin S. Neural networks. A comprehensive foundation // Prentice Hall, Hamilton. 2006.
2. McCulloch W.S., Pitts W. A logical calculus of the ideas immanent in nervous activity // Bulletin of Mathematical Biophysics. 1943. V.5.
3. Morrison A., Diesmann M., Gerstner W. Phenomenological models of synaptic plasticity based on spike timing // Biological Cybernetics. 2008. V. 98(6). P. 459–478.
4. Paugam-Moisy H., Bohte S. Computing with spiking neuron networks, in: Handbook of natural computing // Springer. 2012. P. 335–76.
5. Song S., Miller K.D., Abbott L.F. Competitive Hebbian learning through spike-timing-dependent synaptic plasticity // Nature Neuroscience. 2000. V.3. P. 919–926.
6. Izhikevich E.M. Simple model of spiking neurons // IEEE Transactions on neural networks. 2003. V. 14(6). P. 1569–1572.
7. Quiñero R., Panzeri S. Principles of Neural Coding // CRC Press, 2013.
8. Lobov S.A., Zhuravlev M.O., Makarov V.A., Kazantsev V.B. Noise Enhanced Signaling in STDP Driving Spiking Neuron Network // Math. Model. Nat. Phenom. 2017. V.12(4). P.109–124.
9. Tyukin I., Gorban A.N., Calvo C., Makarova J., Makarov V.A. High-dimensional brain: A tool for encoding and rapid learning of memories by single neurons” // Bulletin of Mathematical Biology, 2018.

WORKSHOP ОТ КОМПАНИИ INTEL

А. В. ДЕМИДОВСКИЙ

Национальный исследовательский университет «Высшая школа экономики»,
Нижегородский филиал
А/О «Интел А/О», Нижний Новгород
ademidovskij@hse.ru
alexander.demidovskij@intel.com

ОСОБЕННОСТИ ПРОГРАММНЫХ И АППАРАТНЫХ СРЕДСТВ ДЛЯ ОПТИМИЗАЦИИ ИНФЕРЕНСА ОБУЧЕННЫХ НЕЙРОННЫХ СЕТЕЙ В РАМКАХ СРЕДЫ OPENVINO*

Рассматривается задача ускорения инференса нейронных сетей с помощью различных техник, включающих пакетную обработку входных данных, параллелизацию выполнения сети на аппаратном обеспечении, упрощение топологии сети и т.д. Исследуется вопрос универсальных правил объединения некоторых слоёв нейронной сети как во время стадии, предшествующей инференсу, так и во время непосредственного выполнения нейронной сети на целевом устройстве. В качестве основного инструмента для инференса используется открытая среда OpenVINO, предоставляющая широкие возможности оптимизации процесса выполнения сети на целевом аппаратном обеспечении.

Ключевые слова: инференс, нейронные сети, оптимизация, глубокое обучение

Введение

Повсеместное развитие глубокого обучения позволяет использовать нейронные сети в качестве надёжных инструментов при решении задач реального мира. Однако современные нейронные сети оказываются достаточно требовательными к аппаратному обеспечению, на котором происходит тренировка и инференс. При этом с прикладной точки зрения, время работы нейронной сети должно быть минимальным, чтобы было возможным использовать нейронную сеть в режиме реального времени.

* Данная работа выполнена при частичной поддержке РФФИ, проект № 19-37-90058.

Например, если существует задача распознавания пешеходов по данным, приходящим с видеокамер, то нейронная сеть должна тратить не более 30 мс на каждое изображение в этом видео, иначе могут возникнуть трагические последствия для участников дорожного движения. В рамках данной работы исследуется возможность ускорения инференса нейронной сети, то есть выполнения или полного обчёта сети на выбранном аппаратном обеспечении, при этом вопросы обучения и ускорения именно обучения нейронной сети не рассматриваются.

Важной особенностью развития методов ускорения нейронных сетей является широкое многообразие устройств различных архитектур, для многих из них инференс сети невозможен без дополнительных манипуляций с исходной сетью. Например, это касается различных встроенных платформ, таких как: GNA (Gaussian Neural Accelerator), Intel® Movidius NCS2 (Neural Compute Stick) и так далее. Поэтому вопрос эффективного инференса нейронной сети на целевом устройстве является актуальной задачей для большого числа пользователей. В рамках данной работы рассматриваются методы оптимизации нейронных сетей, предложенные во фреймворке с открытым исходным кодом OpenVINO [1].

Данная работа имеет следующую структуру. В Разделе 2 представлен краткий обзор существующих методов оптимизации инференса сети. Раздел 3 посвящен различным способам его ускорения. Наконец, формируются выводы и направления дальнейшего исследования.

2. Обзор литературы

Существует большое количество работ, посвященных ускорению работы нейронной сети. Инференс сети – это выполнение вычислительного графа, состоящего из операций [2]. С точки зрения уровня абстракции, ускорение каждой отдельной операции является крайне близким к использованию системных ресурсов и может осуществляться, например, через подключение специальных библиотек: MKL-DNN [3], OpenBLAS [4]. При таком способе ускорения инференса не учитывается потенциал ускорения сети через анализ и оптимизацию нейронной сети как графовой структуры. Кроме того, включение любой библиотеки в уже имеющееся приложение может быть очень дорогим решением как с точки зрения реализации, так и с точки зрения дальнейшей поддержки продукта.

С другой стороны, существуют работы, посвященные проведению оптимизации сети без учёта особенностей целевого аппаратного обеспечения [5]. Такие изменения позволяют сохранить оригинальную точность нейронной сети, а также ускорить её работу, однако такой вид оптимизаций является очень специфичным для каждой следующей нейронной сети и имеет форму эвристик и предположений о структуре сети.

Также существуют работы, которые посвящены использованию компиляторов глубоких нейронных сетей. К таковым относятся: TVM [6],

Tensor comprehensions [7], Glow [8]. Каждая из них различается по количеству уровней, на которых можно осуществлять оптимизацию нейронной сети: от уровня простых операций до уровня оптимизаций сети как вычислительного графа.

Другим известным способом ускорения нейронных сетей является уменьшение разрядности вычислений от 32-битного числа с плавающей запятой к 16-битному, а также к целым числам различного порядка битности (8 бит на число, 4 бит, 1 бит и т.д.). Вместе с ускорением работы, квантизация к значениям меньшей разрядности позволяет снизить требования на объемы потребляемой памяти, а также энергозатрат устройства, что особенно актуально для встраиваемых блоков. Существует большое количество типов оптимизации [9, 10]: бинаризация (сведение весов либо к -1 либо к 1) [11], квантизация к числам с фиксированной точностью [12], адаптивная квантизация [13] и так далее.

Наконец, существует большое количество способов оптимизации нейронных сетей, которые нацелены либо на какое-то конкретное устройство (CPU/GPU) [5], либо на какой-то специфичный сценарий использования. В рамках данной работы исследуются возможности оптимизации нейронных сетей, предлагаемые в среде OpenVINO. Некоторые описанные оптимизации могут не являться абсолютно новыми, однако предлагается использовать данные методы одновременно для получения более высокого результата.

3. Способы ускорения инференса сети

3.1. Использование пакетной обработки входных данных

Нейронная сеть, как вычислительный блок, представляет собой набор операций, которые последовательно применяются ко входным данным. В силу субсимволичности производимых вычислений происходит манипулирование тензорами, и сети безразлично, обрабатывает ли она, например, одну картинку в единицу времени или сразу несколько. Иными словами, сеть может быть организована таким образом, что количество входных данных может различаться, и это позволяет одновременно обрабатывать пакет входных данных («батч») за один проход по нейронной сети. За счёт этого повышается производительность сети. Схема такого выполнения пакетной обработки входов представлена на рис. 1.




Рис. 1. Параллелизация обработки данных с использованием батча

Стоит обратить внимание, что использование батча повышает производительность сети благодаря более эффективному использованию механизмов кеширования весов и активаций при выполнении матричных произведений. Однако использование пакетной обработки не является панацеей, и безразмерное увеличение батча делает сеть крайне требовательной к ресурсам машины и может привести к невозможности обчёта сети на заданном устройстве. Поэтому необходимо производить анализ количества операций с плавающей запятой (FLOP – Floating-Point Operations), а также размер памяти, необходимый для хранения весов и активаций нейронной сети. С инженерной точки зрения, батч может задаваться как на уровне описания топологии (например, OpenVINO IR XML), так и в момент загрузки сети на целевое устройство (например, в OpenVINO Inference Engine).

3.2. Параллелизация на уровне сети

Помимо параллелизации на уровне данных (использование батча), существует возможность параллелизации на уровне выполнения сети как функционального блока. Например, можно выполнять параллельный запуск сети на различных логических ядрах устройства. Схема такого выполнения сети представлена на рис. 2. При этом каждый из параллельных запусков сети может в свою очередь использовать механизм пакетной обработки. Такой способ запуска позволяет, с одной стороны, контролировать вычислительную сложность нейронной сети, сохраняя размер батча на приемлемом уровне, а с другой стороны, использовать архитектурные особенности целевого аппаратного обеспечения.




Рис. 2. Параллелизация обработки данных на уровне сети

С точки зрения рассматриваемого в данной работе фреймворка OpenVINO существуют возможности параллелизации выполнения сети

через использование механизма асинхронных запросов на инференс (“streams” и “asynchronous inference requests”).

3.3. Упрощение структуры сети

В разделах 3.1 и 3.2 рассматриваются варианты ускорения инференса сети через использование пакетной обработки и аппаратных особенностей целевых платформ, при этом сеть воспринимается как чёрный ящик и неделимый функциональный блок. Помимо этого, также возможно проведение некоторых оптимизаций над структурой сети. Таким образом, в результате сокращается набор операций, которые требуется сделать внутри нейронной сети для получения результатов аналогичных тем, которые могут быть получены до оптимизации структуры сети.

До момента самого инференса можно производить анализ нейронной сети с целью обнаружения в ней некоторых закономерностей (паттернов) в связях между слоями сети. Общая идея заключается в объединении слоёв с условием сохранения математической точности расчётов. Примеры таких оптимизаций представлены на рис. 3.




Рис. 3. Способы оптимизации структуры сети. а) Граф сети до оптимизации, содержащий нормализацию по батчу. б) Граф сети после оптимизации, нормализация объединена со свёрточным слоем. в) Граф сети до оптимизации, содержащий линейное преобразование. г) Граф сети после оптимизации, линейное преобразование объединено со свёрточным слоем

Подобные оптимизации не зависят от платформы, на которой сеть будет выполняться, и являются универсальными. В рамках фреймворка OpenVINO такие оптимизации выполняются отдельной компонентой (OpenVINO Model Optimizer) и могут расширяться извне в зависимости от

специфики сети. Общей рекомендацией также является удаление слоёв, необходимых исключительно для тренировки (например, Dropout), а также пре- и постобработки данных, которые могут быть частью обученной нейронной сети.

Помимо универсальных оптимизаций также существует ряд оптимизаций, которые зависят от целевой платформы. Например, в рамках CPU плагина в OpenVINO Inference Engine предлагается ряд оптимизаций, связанных в первую очередь с последовательностями свёрточных слоёв, поэлементных операций и активаций (рис. 4), а также объединение свёрточных слоёв в один (рис. 5).




Рис. 4. Объединение последовательности свёртка-поэлементная операция-активация в один слой. а) Граф сети до оптимизации. б) Граф сети после оптимизации




Рис. 5. Объединение множества свёрточных слоёв в один (с добавлением свойства групповой свёртки). а) Граф сети до оптимизации. б) Граф сети после оптимизации

3.4. Уменьшение разрядности вычислений

При обучении нейронных сетей традиционно используются числа одинарной точности (32-битные числа с плавающей запятой). Использование такого диапазона позволяет получать нейронные сети высокой точности. Однако выполнение арифметических операций над такими числами оказывается весьма дорогостоящим, и такая точность оказывается зачастую излишней. Поэтому в последнее время активно исследуются способы уменьшения разрядности нейронных сетей. При этом важно понимать, что уменьшение разрядности используемых в нейронной сети чисел (весов, активаций и т.д.) неизбежно приводит к ухудшению качества результатов самой нейронной сети: чем ниже разрядность, тем менее точной оказывается модель.

Самым безболезненным оказывается переход с чисел одинарной точности на числа половинной точности (16-битные числа с плавающей запятой). Потери в точности оказываются настолько малы, что такой формат становится стандартом в рамках фреймворка OpenVINO для формирования нейронных сетей, предназначенных для инференса. Дальнейшее уменьшение разрядности, например до 8-битных целых чисел, уже невозможно без внешнего вмешательства – требуется найти правильные коэффициенты для перевода из чисел одинарной точности в значительно меньший диапазон целых 8-битных чисел. Это возможно либо через дообучение модели, либо с помощью посттренировочной квантизации. Последний способ доступен в OpenVINO Calibration Tool и позволяет получать контролируемое падение точности модели на заданном наборе входных данных.

Результат квантизации в числа меньшей точности позволяет значительно ускорить инференс модели, уменьшить занимаемый размер, снизить энергопотребление, уменьшить вычислительную сложность модели. При этом должен соблюдаться баланс точности и скорости работы сети, так как для некоторых случаев, связанных, например, с медициной или безопасностью дорожного движения, точность модели играет решающую роль.

Эксперименты

Эксперименты проводились на компьютере со следующими вычислительными характеристиками: Intel Core i7-8700K 3.7GHz. Из полученных результатов можно заметить влияние выбранных параметров (размер батча модели, количество OpenVINO «стримов»). В качестве фреймворка для инференса использовалась версия OpenVINO 2019R2. Результаты представлены в табл. 1. Важно обратить внимание на то, как квантизация модели в 8-битные целые числа влияет на скорость работы нейронной сети, а именно ускоряет работу сети в среднем в 1.56 раз. При этом требуется

учитывать также значение latency – времени на обработку одного изображения. Например, для нейронных сетей, работающих с потоковым видео, требуется тратить не более 30 мс на обработку одного изображения.

Таблица 1

**Результаты инференса нейронных сетей через CPU плагин
OpenVINO**

Разрядность расчётов	Настройки {батч, # стримов OpenVINO}	Googlenet-v2 ¹ (Caffe)		SSD Mobilenet ² (Caffe)		Mobilenet-v2-1.4.224-v1 ³ (Tensorflow)	
		FPS ⁴	Lat. ⁵ , мс	FPS	Lat., мс	FPS	Lat., мс
FP32 ⁶	(1, 1)	141.1	7.0	206.2	4.6	225.1	4.1
	(1, 4)	173.3	22.9	227.5	16.6	263.1	12.1
	(2, 8)	170.3	72.2	208.4	68.5	248.4	66.4
	(8, 8)	171.3	286.4	210.8	256.5	263.3	255.6
INT8 ⁷	(1, 1)	272.0	3.6	184.2	5.2	258.7	3.2
	(1, 4)	313.9	12.7	294.2	10.7	348.6	8.5
	(2, 8)	315.0	38.6	312.1	57.1	435.7	33.0
	(8, 8)	315.2	154.2	300.7	300.7	507.4	103.5

Выводы

В данной работе рассматриваются вопросы эффективного запуска нейронной сети. Существует ряд оптимизаций как на уровне структуры сети, так и на уровне разрядности вычислений. Кроме того, ускорение инференса возможно через использование аппаратных возможностей целевой платформы, а также через использование пакетной обработки вход-

¹ https://github.com/BVLC/caffe/tree/master/models/bvlc_googlenet

² <https://github.com/shicai/MobileNet-Caffe>

³ https://storage.googleapis.com/mobilenet_v2/checkpoints/mobilenet_v2_1.4_224.tgz

⁴ FPS (Frames Per Second) – количество изображений, обрабатываемых нейронной сетью за одну секунду. Чем выше это значение, тем производительнее нейронная сеть.

⁵ Latency – время, требуемое для обработки одного изображения. Чем ниже это значение, тем лучше.

⁶ FP32 – 32-битные числа с плавающей запятой

⁷ INT8 – 8-битные целые числа

ных данных. Поиск лучшей комбинации предложенных оптимизаций очень специфичен для каждой отдельной нейронной сети и требует большой инженерной работы. Стоит отметить наличие фреймворка OpenVINO, который предоставляет возможности применения всех предложенных оптимизаций, позволяет облегчить поиск оптимальной комбинации оптимизаций, а также упрощает процесс перехода на ускорители различного рода в силу унифицированного программного интерфейса. В качестве дальнейшего направления данного исследования рассматривается проведение экспериментов для сравнения выигрыша, получаемого от применения каждой отдельной оптимизации, а также от их комбинаций вместе с выработкой общих рекомендаций для популярных нейросетевых архитектур.

Список литературы

1. OpenVINO. URL: <https://github.com/openclldt> [Дата доступа: 21.09.19]
2. Liu, Yizhi, [et al.]. Optimizing {CNN} Model Inference on CPUs. 2019 {USENIX} Annual Technical Conference ({USENIX}{ATC} 19). 2019.
3. MKL-DNN. URL: <https://github.com/intel/mkl-dnn> [Дата доступа: 21.09.19]
4. OpenBLAS. URL: <http://www.openblas.net/> [Дата доступа: 21.09.19]
5. Vanhoucke, Vincent, Andrew Senior, and Mark Z. Mao. Improving the speed of neural networks on CPUs. (2011).
6. ChenTianqi, [et al.]. TVM: end-to-end optimization stack for deep learning. arXiv preprint arXiv:1802.04799 (2018).
7. Vasilache Nicolas, [et al.]. Tensor comprehensions: Framework-agnostic high-performance machine learning abstractions. arXiv preprint arXiv:1802.04730 (2018).
8. Rotem Nadav, [et al.]. Glow: Graph lowering compiler techniques for neural networks." arXiv preprint arXiv:1805.00907 (2018).
9. Ding Ruizhou, [et al.]. Quantized deep neural networks for energy efficient hardware-based inference // Proceedings of the 23rd Asia and South Pacific Design Automation Conference. IEEE Press, 2018.
10. Choi Yoojin, Mostafa El-Khamy, and Jungwon Lee. Towards the limit of network quantization. arXiv preprint arXiv:1612.01543 (2016).
11. Courbariaux Matthieu, Yoshua Bengio, and Jean-Pierre David. Binaryconnect: Training deep neural networks with binary weights during propagations // Advances in neural information processing systems. 2015.
12. Gupta, Suyog, [et al.]. Deep learning with limited numerical precision // International Conference on Machine Learning. 2015.
13. Han Song, [et al.]. Learning both weights and connections for efficient neural network // Advances in neural information processing systems. 2015.

Научное издание

**XXI МЕЖДУНАРОДНАЯ НАУЧНО-ТЕХНИЧЕСКАЯ
КОНФЕРЕНЦИЯ
"НЕЙРОИНФОРМАТИКА-2019"**

Сборник научных трудов
В 2-х частях
Часть 2

Редакторы: *В.А. Дружинина, О. П. Котова*
Корректоры: *О. П. Котова, В.А. Дружинина*
Компьютерная верстка *Д. А. Юдин*

Подписано в печать 30.09.2019. Формат $60 \times 84 \frac{1}{16}$. Усл. печ. л. 13,5.
Уч.-изд. л. 12,4. Тираж 150 экз. Заказ № 162.
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