РОССИЙСКАЯ НЕЙРОСЕТЕВАЯ АССОЦИАЦИЯ

МИНИСТЕРСТВО ОБРАЗОВАНИЯ И НАУКИ РОССИЙСКОЙ ФЕДЕРАЦИИ

ГОСУДАРСТВЕННАЯ КОРПОРАЦИЯ ПО АТОМНОЙ ЭНЕРГИИ «РОСАТОМ»

НАЦИОНАЛЬНЫЙ ИССЛЕДОВАТЕЛЬСКИЙ ЯДЕРНЫЙ УНИВЕРСИТЕТ «МИФИ»

НАУЧНО-ИССЛЕДОВАТЕЛЬСКИЙ ИНСТИТУТ СИСТЕМНЫХ ИССЛЕДОВАНИЙ РАН

НЕЙРОИНФОРМАТИКА-2023

XXV МЕЖДУНАРОДНАЯ НАУЧНО-ТЕХНИЧЕСКАЯ КОНФЕРЕНЦИЯ

СБОРНИК НАУЧНЫХ ТРУДОВ

- **ТЕОРИЯ НЕЙРОННЫХ СЕТЕЙ**
- **АДАПТИВНОЕ ПОВЕДЕНИЕ И ЭВОЛЮЦИОННОЕ МОДЕЛИРОВАНИЕ**
- **НЕЙРОИНФОРМАТИКА И ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ**
- **НЕЙРОМОРФНЫЕ ВЫЧИСЛЕНИЯ И ГЛУБОКОЕ ОБУЧЕНИЕ**
- **НЕЙРОБИОЛОГИЯ**
- **НЕЙРОННЫЕ СЕТИ И КОГНИТИВНЫЕ НАУКИ**
- **ПРИКЛАДНЫЕ НЕЙРОСЕТЕВЫЕ СИСТЕМЫ**

МОСКВА

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

XXV МЕЖДУНАРОДНАЯ НАУЧНО-ТЕХНИЧЕСКАЯ КОНФЕРЕНЦИЯ «НЕЙРОИНФОРМАТИКА-2023»: Сборник научных трудов. М.: НИЯУ МИФИ, 2023. – 392 с.

Сборник научных трудов содержит доклады, включенные в программу XXV МЕЖДУНАРОДНОЙ НАУЧНО-ТЕХНИЧЕСКОЙ КОНФЕРЕНЦИИ «НЕЙРОИНФОРМАТИКА-2023», проходившей в г. Москве 23–27 октября 2023 г. Тематика конференции охватывает широкий круг вопросов: методические вопросы нейроинформатики, теория нейронных сетей и глубокое обучение, нейробиология, модели адаптивного поведения и когнитивные исследования, нейронные сети для управления, обработки изображений и временных рядов, а также другие приложения нейроинформатики.

В сборник включены доклады, посвященные теоретическим исследованиям искусственных нейронных сетей и их применению в задачах управления, прогнозирования и распознавания образов, моделированию в нейробиологии, когнитивным исследованиям, адаптивному поведению и эволюционному моделированию.

Ответственный редактор *А.Г. Трофимов*

Статьи получены до 30 июня 2023 года.
Материалы издаются в авторской редакции.

ISBN 978-5-7262-3002-3

© *Национальный исследовательский ядерный университет «МИФИ», 2023*

Оригинал-макет подготовлен *М.В. Макаровой*

Подписано в печать 23.10.2023. Формат 60×84 1/16.
Печ. л. 24,5. Тираж 120 экз. Изд. № 009-2. Заказ № 93.

Национальный исследовательский ядерный университет «МИФИ»
Типография НИЯУ МИФИ
115409, Москва, Каширское ш., 31

ОРГАНИЗАТОРЫ КОНФЕРЕНЦИИ

- Российская нейросетевая ассоциация
- Национальный исследовательский ядерный университет «МИФИ» (НИЯУ МИФИ)
- Московский физико-технический институт (национальный исследовательский университет)
- Министерство образования и науки Российской Федерации
- НИЦ «Курчатовский институт»
- Государственная корпорация по атомной энергии «Росатом»
- Научно-исследовательский институт системных исследований РАН (НИИСИ РАН)
- Московский авиационный институт (национальный исследовательский университет), МАИ
- Институт искусственного интеллекта AIRI

ОРГАНИЗАЦИОННЫЙ КОМИТЕТ КОНФЕРЕНЦИИ

Председатель – Шевченко В.И. (НИЯУ МИФИ, Москва)
Зам. председателя – Климов В.В. (НИЯУ МИФИ, Москва)
Зам. председателя – Юдин Д.А. (МФТИ, Москва)
Акопов Э.И. – НИИСИ РАН, Москва
Карандашев Я.М. – НИИСИ РАН, Москва
Киселев М.В. – ЧГУ им. И.Н. Ульянова, Чебоксары
Райгородский А.М. – МФТИ, Москва
Смирнитская И. А. – НИИСИ РАН, Москва
Сохова З.Б. – НИИСИ РАН, Москва
Трофимов А.Г. – НИЯУ МИФИ, Москва
Тюменцев Ю.В. – МАИ, Москва
Ученый секретарь – Бесхлебнова Г.А. (НИИСИ РАН, Москва)

ПРОГРАММНЫЙ КОМИТЕТ КОНФЕРЕНЦИИ

Председатель – чл.-кор. РАН Крыжановский Б.В. (НИИСИ РАН, Москва)
Сопредседатель – Горбань А.Н. (University of Leicester, Great Britain)
Зам. председателя – Дунин-Барковский В. Л. (МФТИ, Москва)
Зам. председателя – Редько В.Г. (НИИСИ РАН, Москва)
Зам. председателя – Тюменцев Ю.В. (МАИ, Москва)
Abraham A. – Machine Intelligence Research Labs (MIR Labs), Scientific Network for Innovation and Research Excellence Washington, USA
Baidyk T. – The National Autonomous University of Mexico
Borisyuk R. – Plymouth University, United Kingdom
Cangelosi A. – Plymouth University, United Kingdom
Dosovitskiy A. – Albert-Ludwigs-Universität, Freiburg, Germany
Golovko V. A. – Brest State Technical University, Belarus
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
Narynov S. – Alem Research, Almaty, Kazakhstan
Pareja-Flores C. – Universidad Complutense de Madrid, Spain
Tsodyks M. – Weizmann Institute of Science, Rehovot, Israel
Wunsch D. – Missouri University of Science and Technology
Академик РАН Анохин К.В. – Институт перспективных исследований мозга МГУ им. М.В. Ломоносова
Академик РАН Балабан П.М. – ИВНД и НФ РАН, Москва

Бурцев М.С. – президент РАСНИ
Введенский В.Л. – НИЦ «Курчатовский институт», Москва
Доленко С.А. – НИИЯФ им. Д.В. Скобельцына МГУ, Москва
Ежов А.А. – ГНЦ РФ ТРИНИТИ, Москва
Каганов Ю.Т. – МГТУ им. Н.Э. Баумана, Москва
Кирой В.Н. – НИТЦ нейротехнологий ЮФУ, Ростов-на-Дону
Литинский Л.Б. – НИИСИ РАН, Москва
Макаренко Н.Г. – ГАО РАН, Санкт-Петербург
Мишулина О.А. – НИЯУ МИФИ, Москва
Оселедец И.В. – Сколковский институт науки и технологий, AIRI
Панов А.И. – ФИЦ ИУ РАН
Самсонович А.В. – НИЯУ МИФИ, Москва
Сысоев И.В. – СФ ИРЭ РАН, Саратов
Терехов С.А. – РАНИ
Трофимов А.Г. – НИЯУ МИФИ, Москва
Ушаков В.Л. – Институт перспективных исследований мозга МГУ им. М.В. Ломоносова
Шапошников Д.Г. – НИТЦ нейротехнологий ЮФУ, Ростов-на-Дону
Шепелев И.Е. – НИТЦ нейротехнологий ЮФУ, Ростов-на-Дону
Шумский С.А. – МФТИ, Москва
Юдин Д.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-2023 представлены доклады по проблемам теории нейронных сетей, нейробиологии, моделям адаптивного поведения, нейросетевому моделированию объектов и систем, обработке 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. За круглым столом «Нейроинформатика сознания» участники конференции, исходя из имеющегося на данный момент коллективного опыта и знаний, обсудят вопросы моделирования сознания и интеллекта.

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

За прошедшие годы конференция НЕЙРОИНФОРМАТИКА сложилась как представительный и многоплановый по тематике научный форум. В его работе принимают участие и известные ученые, и молодые специалисты, аспиранты и студенты. Желаем всем участникам конференции плодотворной работы, активного сотрудничества и новых творческих идей.

Оргкомитет

СОДЕРЖАНИЕ

Секция

ЛЕКЦИИ ПО НЕЙРОИНФОРМАТИКЕ

МАКАРЕНКО Н.Г., УШАКОВ В.Л., РЫБИНЦЕВ А.С., КАРТАШОВ С.И., МОСИНА Л.Е.
Дискретная кривизна графов структурного коннектома для диагностики шизофрении 12

Секция

ТЕОРИЯ НЕЙРОННЫХ СЕТЕЙ

ШИБЗУХОВ З.М.
Некоторые робастные варианты метода главных компонент 27
РОДИОНОВ Д.О.
Рациональная аппроксимация ядра свертки решения волнового уравнения в канале с помощью нейронной сети для построения прозрачных граничных условий 36
ВИТЮГОВА Ю.М., ЕФИТОРОВ А.О., ШИРОКИЙ В.Р.
Сравнение методов отбора входных признаков на основе анализа весов нейронной сети 44

Секция

АДАПТИВНОЕ ПОВЕДЕНИЕ И ЭВОЛЮЦИОННОЕ МОДЕЛИРОВАНИЕ

EL-KHATIB SAMER, SKOBTSOV YURI, RODZIN SERGEY
Determination of optimal heuristic image segmentation coefficients for modified Ant Colony optimization method for complexly structured images 54
МАКАРОВ М.В., СЕМЕНОВ И.А., ПИДЖАКОВА Н.С.
Система логического вывода для нового типа эвристических решений в рамках адаптивного управления мобильным роботом 61
ФЕДОРОВ К.А., НАЗАРЬКО М.Ю., САМСОНОВИЧ А.В.
Управление обучением нейронных сетей с помощью генетического алгоритма 68

Секция

НЕЙРОИНФОРМАТИКА И ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ

КУРЬЯН В.Е.
Аксиомы построения графа модели мира 78

Секция

НЕЙРОМОРФНЫЕ ВЫЧИСЛЕНИЯ И ГЛУБОКОЕ ОБУЧЕНИЕ

ДОРОГОВ А.Ю.
Реализация памяти образов в классе быстрых нейронных сетей 88
ЧАПЛИНСКАЯ Н.В., БАЗЕНКОВ Н.И.
Обучение импульсной нейронной сети
за счет механизмов миелинизации и демиелинизации 98
ТАРАНИН М.В., ТАРАНИН С.В.
Модель цветной спайковой видеокамеры 106
АНТОНОВ Д.И., СУХОВ С.В.
Обучение импульсных нейронных сетей-классификаторов
с помощью локальных правил 116

Секция

НЕЙРОБИОЛОГИЯ

МЫСИН И.Е.
Адаптация методологии машинного обучения
для моделирования нейронных сетей мозга 126
БИБИКОВ Н.Г.
Нейроны слуховой коры ненаркотизированной кошки
воспроизводят быстрые изменения длительных сигналов 133
ПРОСКУРА А.Л., ВЕЧКАПОВА С.О., РАТУШНЯК А.С.
Инсулин как модулятор плотности глутаматных рецепторов 141
ВОРОНКОВ Г.С.
Существует ли внутримозговой экран
для субъективных зрительных образов 149
СЫСОЕВ И.В., КОРНИЛОВ М.В., ЕГОРОВ Н.М., СЫСОЕВА М.В.
Математическая и радиофизическая модели генератора
основного ритма лимбической эпилепсии 159
РАТУШНЯК А.С., ПРОСКУРА А.Л.,
ВЕЧКАПОВА С.О., ХУСАИНОВ Р.Р.
Принципы моделирования возникновения и эволюции
негэнтропийных информационных систем 166

РОГАЧЁВ А.О., СЫСОЕВА О.В.
Применение функции временного отклика
для изучения нейрофизиологических механизмов восприятия речи
в экологически валидных условиях 175
БРУСИЛОВСКИЙ Л.И., БРЮХОВЕЦКИЙ А.С., КОЖИН С.П.
Исследования когнитивных микроволновых излучений
головного мозга человека как новый тип
микроволновых энцефалограмм 183

Секция

НЕЙРОННЫЕ СЕТИ И КОГНИТИВНЫЕ НАУКИ

КОЗУНОВ В.В.
Пространственное разрешение для анализа соответствия
представлений в исследованиях
с помощью магнитоэнцефалографии 192
BRUEVA A., EDELEVA J.
Negotiating cognitive load through cognitive skills,
foreign language proficiency and the state of anxiety
in foreign language oral performance 202
КЛИНЬШОВ В.В., КОВАЛЬЧУК А.В.
Частотный хаос и длительность памяти
в спайковых нейронных сетях..... 213
КОНОНОВ Р.А., МАСЛЕННИКОВ О.В.
Популяционная динамика в рекуррентных нейронных сетях:
обучение с подкреплением задачам когнитивной нейронауки 222
КРЫЛОВ А.К.
Нелогичность и культуроспецифичность мышления
при решении логических задач 231
ПОЛЕВАЯ С.А., КОВАЛЬЧУК А.В., ЕРЕМИН Е.В.,
ПЕРМЯКОВ С.А., ФЕДОТЧЕВ А.И., ПАРИН С.Б.
Язык ритмограмм для отображения
функциональных состояний человека..... 241
EDELEVA J., SMETANINA O.A.,
MESHCHERYAKOVA A.A., KUSHINA N.
German-as-a-Foreign-Language (GFL) Learners' Reliance on 'Early'
and 'Late' Morphological Cues for Structural Analysis:
The Role of Cognitive Load..... 250
SHATS V.N.
Principle Splitting of Finite Set in Classification Problem..... 262

Секция

ПРИКЛАДНЫЕ НЕЙРОСЕТЕВЫЕ СИСТЕМЫ

БУХ А.В., РЫБАЛОВА Е.В., ШЕПЕЛЕВ И.А., ВАДИВАСОВА Т.Е.
Классификация музыкальных интервалов
в цепочке осцилляторов ФитцХью-Нагумо 271
ШЛАПАК Н.П.
Исследование возможности использования
предобученного автоэнкодера для анализа
с помощью метода главных компонент 274
СОЛОВЬЕВ И.А., КЛИНЬШОВ В.В.
Пороги устойчивости аттракторов сети Хопфилда 283
ШАМАРИНА Е.А., ГУСЕВА А.И., КИРЕЕВ В.С.
Сентимент-анализ на основе нейросетей-трансформеров..... 292
КУЗЬМЕНКО А.В., КИРЕЕВ В.С.
Классификация методов извлечения реляционных троек
из текстов на естественном языке 302
КАЛИНИНА А.Ю., КИРЕЕВ В.С.
Визуализация корпуса документов с помощью извлечения
сущностей и связей предметной области на основе
нейросетевой модели глубокого обучения T5 312
КУЛЯБИНА Е.В., КУЛЯБИНА Т.В., МОРОЗОВА В.В., МОРОЗОВ В.Ю.
Вопросы исследования и выбора методов и средств
обеспечения точности и валидации при создании
виртуального образца живой клетки для моделирования
внутриклеточных процессов методами нейроинформатики 321
БОЛОТНИКОВА А.А., ШЛАПАК Н.П.
Применение нейронных сетей в прогнозировании изменения
изотопного состава ТВС реактора ВВЭР-1000 328
ЧЕРНЫШЕВ Л.С., АНТОНОВ И.М.
Система оптимального управления торговым процессом
с использованием искусственной нейронной сети
и метода оптимизации Дельта..... 337
НОВОЖИЛОВ К.А., КОЖЕВНИКОВ С.П., КОЗЛОВ Д.С.,
КОМЫШЕВ Д.А., СЕРГЕЕВ В.Г.
Диагностика болезни Паркинсона с использованием методов
глубокого машинного обучения
по данным электроэнцефалографии..... 353
ИЛЛАРИОНОВ Е.А.
Адаптивная нейросетевая модель
для оцифровки рукописного текста 361

САЙБОДАЛОВ М.Х., КАРАНДАШЕВ Я.М.
Применение самообучающихся алгоритмов
для детекции аномалий на рентгеновских снимках..... 370
ХРЯЩЕВ В.В.
Исследование нейросетевых алгоритмов для системы поддержки
принятия врачебного решения при исследовании желудка
в эндоскопии..... 380

Именной указатель авторов.....391

Секция

Лекции по нейроинформатике

Н.Г. МАКАРЕНКО[1], В.Л. УШАКОВ[2,3,4], А.С. РЫБИНЦЕВ[1], С.И. КАРТАШОВ[5], Л.Е. МОСИНА[2]

[1]Главная (Пулковская) астрономическая обсерватория РАН, Санкт-Петербург
[2]Национальный исследовательский ядерный институт, Москва
[3]Институт перспективных исследований мозга МГУ им. М.В. Ломоносова, Москва
[4]Психиатрическая клиническая больница №1 им. Н.А. Алексеева ДЗМ, Москва
[5]Национальный исследовательский центр Курчатовский институт, Москва
ng-makar@mail.ru

ДИСКРЕТНАЯ КРИВИЗНА ГРАФОВ СТРУКТУРНОГО КОННЕКТОМА ДЛЯ ДИАГНОСТИКИ ШИЗОФРЕНИИ

Статья описывает технику и результаты применения 2-х дискретных вариантов кривизны Риччи к сети, кодирующей коннектомы коры для 2-х выборок. Первая из них (A) – здоровые люди; вторая (B) – пациенты с диагнозом шизофрении. Проверялась гипотеза о взаимосвязи заболевания шизофренией и структурной организации проводящих путей головного мозга. Анализ проводящих путей головного мозга проводился с использованием матриц структурных связностей на основе данных трактографии (diffusion tensor image, DTI) в режиме получения данных B0 и по 64-м векторным направлении (значение b составляло 1500 с/мм^2) с TE = 101 мс и TR = = 13700 мс. После фильтрации нулевых (относительно весов трактограммам) ребер, на сети обеих выборок вычислялись два варианта дискретной кривизны: (FR) – *Формана–Риччи* и (OR) – *Оливье–Риччи*. При этом каждая из выборок (A) и (B) делилась пополам после случайного итеративного перемешивания и, для каждого варианта деления, оценивалось значение кривизны ребер сети. Было обнаружена существенная различие в сходимости, по бинам, разницы гистограмм кривизны при статистическом перемешивании (A) и (B). Разница гистограмм 2-х половинок выборки (A) сходилась к ожидаемому минимуму, с ростом числа перемешиваний. Для выборка (B), больных шизофренией, сходимость с увеличением степени перемешивания, отсутствовала. Полученный результат указывает на возможную связь психический отклонений с кривизнами структурного коннектома.

Ключевые слова: *графы, дискретный лапласиан, дискретная кривизна Риччи, МРТ, DTI, трактография, диагностика шизофрении.*

Введение

Британский математик, лауреат премии Филдса (1998 г.), Уильям Тимоти Гауэрс, в своем замечательном эссе[1] «Две культуры в математике» отметил, что такой объект как граф, можно быстро объяснить и понять: «*Совершенно не обязательно читать много литературы перед тем, как приступить к решению конкретной задачи. Конечно, полезно знать некоторые из наиболее важных методов, но интересные проблемы, как правило, остаются нерешёнными, как раз потому, что эти техники к ним применить не удаётся*». Действительно, применение графов для прикладных задач ограничивалось тогда лишь различными коэффициентами кластеризации, мотивами, скейлинговыми показателями, и моделями случайных графов Эрдеша-Реньи. Тем не менее, даже этот инструментарий привел к открытию интересных эффектах в моделях «тесного мира» [1], ограничениям числа социальных связей (числа Данбара) участника сети, степенных законов в когнитивных сетях[2] [2], и принципа – «сила слабых связей» [3]. Сетевые подходы становятся популярными в биологии и нейрофизиологии [4]; более того сети и графы положены в основу будущей «Физики Всего» [5].

Сам граф действительно является чрезвычайно простой конструкцией $G(V,E)$, составленной из двух конечных множеств: непустого множества вершин $\{V\}$ и множества их парных связей-ребер $\{E\}$. Для удобства кодирования графами распределенной системы, вершины обычно снабжают весами, (в простейшем варианте это степени вершины). Сами ребра, кроме весов, измеряющих «силу» связи, наделяют еще и ориентацией.

Более сложной конструкцией является сеть, имеющая симплициальную структуру: в ней, кроме ребер, присутствуют грани, также наделенные весами. Симплициальные сети называют также сетями высокого порядка [6]; они позволяют моделировать «сети-сетей», т.е. гиперграфы. Методы анализа таких конструкций стали существенно богаче: взвешенные графы и

[1] Gowers W. T. et al. The two cultures of mathematics // Mathematics: frontiers and perspectives. 2000. V. 65. P. 65.

[2] Интересная информация о когнитивных графах содержалась в лекции О.П. Кузнецов, Л.Ю. Жилякова «Сложные сети и когнитивные науки»: Нейроинформатика, 2015.

сети можно снабдить подходящими «метриками», которые описывают локальную и глобальную структуру сети и позволяют не только сравнивать сети между собой, но и описывать сеть, изменяющую свою структуру во времени, т.е. ее графодинамику[3]. С каждым графом всегда связаны, по меньшей мере, две матрицы: смежности и инцидентности [7, 8]. В качестве дескрипторов для графа можно использовать спектры собственных значений матрицы смежности, точнее ее варианта, который называют матрицей Лапласа-Кирхгофа [8]. Она является дискретной формой обычного лапласиана [9]. Следует заметить, что спектр не является топологическим инвариантом: два графа – треугольник и квадрат гомеоморфны, но имеют разные матрицы смежности и, следовательно, разные спектры. Для симплициальной сети, аналогом дискретного лапласиана является k-лапласиан или оператор Лапласа–Ходжа, который построен на матрицах инцидентности (границ) p-го порядка [10]. Лапласиан Ходжа позволяет обнаруживать дыры в метаболической сети, возможно связанные с разрушением модульной структуры связей при болезни Альцгеймера [11].

Более интересными «метриками» являются дискретные варианты кривизны Риччи, известной из римановой геометрии, которые активно изучают в последнее время [12–14]. Наиболее популярны два варианта. Первым является кривизна *Формана–Риччи* (FR), основанная на дискретном варианте теории Морса и формулах Бохнера [12, 15], вторым – кривизна *Оливье–Риччи* (OR) [16], основанная на метриках Вассерштейна для транспорта меры [17]. Алгоритмы вычисления FR и OR кривизны для ребер сети относительно просты. Полученные оценки тесно связаны с хрупкостью системы и энтропией Больцмана [18]. Это обстоятельство мотивирует использование оценок дискретной кривизны для диверсификации раковых сетей [19] и диагностики «черных лебедей» в динамике финансовых рынков [20].

Мы применяем эту технику в медицинской проблеме диагностики шизофрении, когда графом служит коннектом коры мозга человека.

Одной из актуальных задач в психиатрии является создание объективной оценки диагностирования заболевания шизофренией. На текущий момент не существует единой общепринятой теории патогенеза шизофрении, и постановка диагноза носит субъективный характер мнения врача. Для создания необходимых экспертных систем, на базе ГБУЗ «Психиатрическая клиническая больница № 1 им. Н.А. Алексеева, Департамента здравоохра-

[3] Термин был предложен Марком Айзерманом: Автоматика и телемеханика 1997. Т. 7. С.135.

нения города Москвы» проводится комплексное исследование больных методами нейропсихиатрического тестирования, нейрофизиологического тестирования (морфометрия, трактография, МР-спектроскопии и анализа макромолекулярных фракций, фМРТ и ЭЭГ состояния покоя, фМРТ реакции на личностно-значимые стимулы с применением МРТ-совместимого полиграфа), данные по иммунологическому статусу, транскриптомам и экзомам клеток крови, постмортальный анализ липидомов и траскриптомов различных отделов головного мозга и т.д. Целью упомянутых исследований является выделение значимых объективных маркеров заболевания шизофренией и выявление корреляции между ними. В определенном смысле мы исследуем задачи, перечисленные в обзоре [21].

Данные. Нами использовалась клиническая выборка из 46 пациентов (22 женщины и 24 мужчины, (ср возраст 26,5 ± 5,3 лет), из числа госпитализированных в стационарные отделения клиники с диагнозом шизофрения F20.0 (галлюцинаторно-параноидная) в ГБУЗ «ПКБ № 1 им. Алексеева ДЗМ» и контрольная группа 41 человек (17 женщин и 24 мужчины). Критерии включения: в возрасте от 21 до 35 лет, соответствие состояния критериям шизофрении по МКБ-10 (F20) и DSM-5, праворукость, критика к состоянию сохранением памяти о психотических симптомах, информированное согласие на участие в исследовании. Критериями исключения: шизоаффективные и аффективные расстройства, органические заболевания головного мозга, тяжелые соматические и/или неврологические состояния, потенциально влияющие на физиологию или структуру мозга, признаки злоупотребления ПАВ и общие противопоказания для проведения МРТ. Все испытуемые дали письменное информированное согласие после полного описания процедур исследования согласно Хельсинкской декларации. Результаты настоящей работы являются частью исследовательской программы «Молекулярные и нейрофизиологические маркеры эндогенных заболеваний», проводимой в ГБУЗ «ПКБ 1 ДЗМ», одобренного Независимым междисциплинарным комитетом по этической экспертизе клинических исследований от 14 июля 2017 г. (протокол № 12).

Анализ проводящих путей головного мозга проводился с использованием матриц структурных связностей на основе данных трактографии (diffusion tensor image, DTI) в режиме получения данных B0 и по 64-м векторным направлении (значение b составляло 1500 с/мм^2) с TE = 101 мс и TR = = 13700 мс. Данные были получены для двух направлений фазовых кодирующих градиентов anterior-posterior и posterior-anterior. Толщина среза составляла 2 мм, разрешение в плоскости томографического среза составляло 2 мм, угол отклонения = 90° и поле обзора FOV = 240 × 240 мм^2). угол отклонения = 90° и поле обзора FOV = 240 × 240 мм^2). Диффузионные данные из формата

DICOM сконвертированы в формат NIfTI. Далее с помощью модуля topup в программе FSL (https://fsl.fmrib.ox.ac.uk/fsl/fslwiki/FSL) проведена коррекция артефактов искажений диффузионных данных: проведена оценка искажений двух наборов данных, построена карта неоднородности магнитного поля внутри томографа, после чего данные скорректированы и выровнены в соответствии с полученными картами. Для каждого из испытуемых, принявшего участие в исследованиях, с помощью программного пакета DSI Studio (https://dsi-studio.labsolver.org/download.html) были получены сведения о 14400 трактах проводящих путей (связи между 120 областями головного мозга, в основе которых был взят атлас AAL (https://www.gin.cnrs.fr/en/tools/aal/)). Минимальная длина реконструированных трактов составляла 10 вокселей (20 мм).

Мы проводили исследование применения эффективности методов дискретной римановой геометрии для анализа структурных коннектомов больных шизофренией. Мы предполагали, что признаками шизофрении служат отклонения в значениях дискретной кривизны по сравнению с коннектомами группы здоровых людей. Работа имеет следующую структуру. Первый раздел содержит краткое введение в технику анализа, второй раздел содержит результаты наших оценок эффективности методов дискретной римановой геометрии для анализа структурных коннектомов больных шизофренией. Заключение резюмирует полученные результаты и намечает дальнейшие цели.

Лапласиан и дискретная кривизна на графах: Quick start.

Существует большая библиотека книг посвященных графом и их спектрам (см., например, [7–9]). Поэтому, мы приводим здесь лишь самые неоходимые элементы, да и то в форме примеров.

Матрица Кирхгофа–Лапласа. Обозначим $\{\mathbf{v}_i\}$ множество вершин графа L. Две вершины $\mathbf{v}_i, \mathbf{v}_j$ *смежны* $\mathbf{v}_i \sim \mathbf{v}_j, i \neq j$ если их соединяет ребро. Степенью вершины $\deg(\mathbf{v}_i)$ называют число ребер входящих в нее. Свяжем с графом L матрицу *Кирхгофа–Лапласа*, элементы которой определены выражением:

$$L_{ij} = \begin{cases} \deg(\mathbf{v}_i), \; i = j \\ -1, \; \mathbf{v}_i \sim \mathbf{v}_j \\ 0, \quad \text{if otherwise} \end{cases}$$

$$L = \begin{pmatrix} 2 & -1 & -1 & 0 \\ -1 & 2 & -1 & 0 \\ -1 & -1 & 3 & -1 \\ 0 & 0 & -1 & 1 \end{pmatrix}$$

Рис. 1. Граф и его матрица Кирхгофа–Лапласа

Рассмотрим дважды дифференцируемую функцию $f(x)$ в интервале $(x_0 - h, x_0 + h)$. Используя два его разложения на краях интервала, легко получить приближенное выражение для второй производной (1-мерного лапласиана) в середине интервала:

$$f''(x_0) = \lim_{h\to 0} \frac{2}{h^2}\left\{\frac{f(x_0+h)+f(x_0-h)}{2} - f(x_0)\right\}.$$

Очевидно, что ее значение получается как арифметическое среднее разности значений функции на концах и в центре. Умножим теперь вектор строку (x_1, x_2, x_3, x_4) на третий столбец матрицы L, соответствующей вершине $\mathbf{v}_3$:

$$-\begin{pmatrix} x_1 \\ x_2 \\ x_3 \\ x_4 \end{pmatrix}^T \begin{pmatrix} 2 & -1 & \mathbf{-1} & 0 \\ -1 & 2 & \mathbf{-1} & 0 \\ -1 & -1 & \mathbf{3} & -1 \\ 0 & 0 & \mathbf{-1} & 1 \end{pmatrix} = x_1 + x_2 - 3x_3 + x_4 = \sum\nolimits_{i\sim 3}(x_i - x_3) = \Delta(\mathbf{v}_3).$$

Полагая, что значения нашего вектора определяют значения функции заданной в вершинах графа, мы увидим что полученное выражение совпадает с лапласианом в вершине $\mathbf{v}_3$. Поэтому, матрицу L называют *дискретным лапласианом*. Можно получить строгое доказательство, оправдывающее это название, если получить оценку непрерывного лапласиана из решения уравнение диффузии на конечном множестве дискретных точек

$$\frac{\partial}{\partial t}u(x,t) + \Delta u(x,t) = 0,\ \ u(x,0) = f(x),$$

$$\hat{\Delta} f(x) = \lim_{t\to 0} \frac{1}{t}\frac{(4\pi t)^{-1}}{n}\sum\nolimits_i e^{-\frac{\|x_i - x\|^2}{4t}}\left(f(x) - f(x_i)\right).$$

Диффузное расстояние между точками обусловлено «тепловым гауссовым ядром».

Существует несколько способов получения матрицы L. Так, ее можно получить из матрицы смежности A графа, которая будет отличаться от нее нулями на диагонали, потому что отсутствуют петли в вершинах и изменением знака всех остальных элементов. Если ввести диагональную матрицу весов $D = \left(\deg(\mathbf{v}_{ii})\right)$, $i = 1,2,3,4$, то, очевидно $L = D - A$. Можно использовать матрицу инцидентности, столбцы которой соответствуют ребрам, а строки, вершинам. Для ребра $\left[\mathbf{v}_i, \mathbf{v}_j\right]$. Поскольку граница ребра $\partial\left[\mathbf{v}_i, \mathbf{v}_j\right] = \mathbf{v}_j - \mathbf{v}_i$ определяется как разность вершин, вершине $\mathbf{v}_i$ будет соответствовать –1, а вершине $\mathbf{v}_j$ – +1. Обозначим такую матрицу как B, тогда $L = B^T B$ или используя граничный оператор ∂ для матрицы B получим $\Delta = \partial^T \circ \partial$. В качестве количественной характеристики графа используют спектр собственных значений матрицы L. Кратность нулей для наименьшего собственного значения в этом спектре измеряет число связных компонент графа, а второе из минимальных, собственное значение называют алгебраической связностью графа [9].

Кривизна Риччи и ее дискретные аналоги. Кривизна Риччи измеряет деформацию объема в касательной окрестности некоторой точки, по сравнению с евклидовым образом [22]. Для того, чтобы пояснить идею, рассмотрим случай 2-х сферы. Пусть два путешественника движутся по соседним меридианам, разделенным расстоянием $(\Delta x)_0$, к северному полюсу. Они не догадываются о сферичности поверхности, но пройдя расстояние s обнаруживают, (рис. 2), что расстояние между ними стало $(\Delta x)_s$. Легко вычислить, что уменьшение расстояния описывается следующей приближенной формулой (здесь φ – угол широты):

$$\left(\Delta x\right)_s = \left(\Delta x\right)_0 \cos\varphi \approx \left(\Delta x\right)_0 \left(1 - \frac{\varphi^2}{2}\right) = \left(\Delta x\right)_0 \left(1 - \frac{s^2}{2R^2}\right)$$

Рис. 2. Сокращение расстояния между соседними геодезическими вызванное положительной кривизной

В этом выражении R – радиус сферы, а величина R^2 называется гауссовой кривизной[4]. Заметим, что если заменить путешественников малыми кружками-окрестностями, то при их смещении по меридианам, среднее расстояние между точками двух окрестностей будет уменьшаться быстрее чем расстояние $(\Delta x)_s$. Эта идея и лежит в основе вычисления кривизны Риччи (рис. 3).

Рис. 3. Аналог сокращения расстояния по дуге как уменьшение расстояния между точками соседних окрестностей

[4] Ее удвоенное значение называют в геометрии Римана скалярной кривизной.

Выберем две близких точки (x, y) разделенных расстоянием $\delta = d(x, y)$ на геодезической. Будем параллельно переносить точки ε-окрестности S_x в окрестность S_y точки y. В случае положительной кривизны $Ric(\bar{\mathbf{v}}_{xy}) > 0$, уменьшение среднего расстояния между точками окрестностей определяется формулой [12,13]:

$$\delta\left[1 - \frac{\varepsilon^2}{2(n+2)}\mathrm{Ric}(\bar{\mathbf{v}}_{xy}) + O(\varepsilon^3 + \varepsilon^2\delta)\right].$$

Вычислить бесконечное число парных расстояний между точками практически невозможно, поэтому Оливье предложил заменить области некоторой мерой m_x, m_y, [12, 13, 16]. Тогда, необходимое расстояние (Вассерштейна) получается решением транспортной задачи переноса меры (рис. 5)[5], известной как задача Монжа-Канторовича [12, 14].

Рис. 5. Минимальная работа по переносу массы (меры)
из одной окрестности в соседнюю.
Ее иногда называют «транспортным» расстоянием

Результатом служит следующая формула для оценки кривизны Оливье-Риччи [14, 16]:

$$\kappa(x, y) = 1 - \frac{W_1(m_x, m_y)}{d(x, y)}.$$

[5] Рисунок Ани Курилович.

Здесь $W_1\left(m_x, m_y\right)$ – минимальная работа по переносу массы из одной окрестности в другую, которая измеряется расстоянием Вассештейна [17]. Для графов (рис. 6) эта кривизна довольно просто вычисляется, а массой вершины в простейшем варианте служит ее обратная степень.

$$m_x(y) = \begin{cases} \frac{1}{d_x}, & \text{if } y \sim x; \\ 0, & \text{otherwise.} \end{cases}$$

Рис. 6. Кривизна Оливье–Риччи ребра (x, y) вычисляется переносом массы $m_x(y)$ по всем возможным путям, с учетом числа треугольников, опирающихся на ребро

Для графов не существует обычной метрики, и поэтому ребра, входящие в вершины (x, y), можно считать параллельными. Однако смежность этих двух точек определяется не только их весами, но и весами входящих ребер и даже граней (для симлициальных сетей). Такой подход учитывается в оценке кривизны Формана–Риччи. Ее аналитика довольно сложна и опирается, во-первых, на технику Бохнера в геометрии Римана [22], а во-вторых, на дискретный вариант теории Морса, предложенный Форманом [15]. Мы не имеем возможности изложить здесь детали, однако заметим, что в случае единичных весов, кривизна Формана–Риччи сводиться к очень простому выражению:

$$F(e) = 4 - \deg(\mathbf{v}_1) - \deg(\mathbf{v}_2)\,.$$

Так, для ребра (x, y) на рис. 6 мы получим: $F(xy) = -5$.

В работе [23] было проделано сравнение описанных вариантов OR и FR на одинаковых графах. Качественно, обе кривизны описывают графы сходным образом, но количественно, оценки различаются. Мы использовали оба варианта в своих компьютерных экспериментах. Заметим, что уже сделаны попытки объединить идеи персистентных гомологий, дискретной теории Морса и дискретной кривизны [24]. Они опираются на красивые связи чисел Бетти, свойств Лапласиана и кривизну Риччи. В этой работе, для получения оценок кривизны, мы использовали пакет программ GraphRicciCurvature[6], описанной в [25].

[6] https://github.com/saibalmars/GraphRicciCurvature.

Оценка эффективности методов дискретной римановой геометрии для анализа структурных коннектомов больных шизофренией

На первом этапе были проанализированы гистограммы нормированной степени связности зон интереса в полученных коннектомах больных шизофренией и группы контроля (рис. 7, *а*).

Рис. 7. Гистограммы нормированной степени связности зон интереса в полученных коннектомах больных шизофренией – синий цвет, и группы контроля – оранжевый цвет (*А*). Максимумы степени связности для испытуемых группы контроля и больных шизофренией. По оси ординат величина максимума связности, по оси абсцисс испытуемые (*Б*). График зависимости процента количества трактов в зависимости от порога нормированной степени связности (*В*). Пример изменения индивидуального коннектома при разных уровнях порога нормированной степени связности (*Г*)

Рис. 8. *А* – разностные гистограммы кривизны Формана–Риччи для коннектомов группы больных шизофренией. *Б* – разностные гистограммы кривизны Оливье–Риччи для коннектомов группы больных шизофренией. *В* – разностные гистограммы кривизны Формана–Риччи для коннектомов группы здорового контроля. *Г* – разностные гистограммы кривизны Оливье–Риччи для коннектомов группы здорового контроля. Цветом и числами на рис. *А–Г* отмечено число усреднений. *Д* – зависимость величины максимума различий из разностных гистограмм от числа усредненных гистограмм для кривизны Формана–Риччи (синий цвет – больные шизофренией, красный – группа контроля)

Поскольку максимумы степени связности были индивидуальны для испытуемых группы контроля и больных шизофренией (см. рис. 7, *Б*), то нормирование проводилось на свой индивидуальный максимум. Характер распределения степени связности достаточно похож между группами с некоторым повышением уровня различия в области высоких степеней связности. На данном этапе из дальнейшего анализа были исключены нулевые связи коннектомов, то есть все рёбра, для которых сила связи строго нуль.

Примерно 90 % ненулевых трактов имеют нормированную степень связности ниже 0,2 (см. рис. 7, *В*). Увеличение порога связности до 0,2–0,3 приводит к развалу коннектома на отдельные части (см. рис. 7, *Г*), сформированные ребрами с высокой степенью связности. В дальнейшей работе, чтобы нивелировать эффект влияния степени связности, мы рассматривали невзвешенные графы. Мы разделяли группу больных на две случайным образом, далее строили гистограммы кривизны Формана–Риччи и кривизны Оливье-Риччи для коннектомов каждой группы. Повторяли эту процедуру множество раз, получали усреднённые гистограммы и строили их разности отдельно для кривизны Формана–Риччи (см. рис. 8, *А*) и кривизны Оливье–Риччи (см. рис. 8, *Б*). Аналогично поступали с группой здорового контроля (см. рис. 8, *В*, *Г*). Таким образом, проводилось исследование поведения профиля гистограммы для группы больных шизофренией и группы контроля в зависимости от количества усреднений. Как видно из рис. 8, *А–Г* разница гистограмм 2-х половинок выборки группы контроля сходилась к ожидаемому минимуму, с ростом числа перемешиваний, а для выборки больных шизофренией сходимость с увеличением степени перемешивания, отсутствовала. Далее, имея 100 выборок гистограмм, проводилось кумулятивное усреднение: вначале используется просто первая выборка, затем среднее первой и второй, затем первой, второй и третьей и так далее. На каждом таком шаге мы берем максимум разности по модулю между соответствующими гистограммами. Таким образом проводилась оценка – как сглаживается величина максимальной разности в зависимости от количества слагаемых. На рис. 8, *Д* приведен полученный результат, из которого видно, что для группы больных шизофренией величина максимумов разности выше, чем для группы здорового контроля при усреднениях выше 20. Это может говорить о большей дифференцированности коннектомов больных шизофренией по отношению к норме.

Заключение

Полученные результаты показали перспективность анализа особенностей структурных коннектомов головного мозга на основе расчета дискретных оценок кривизны Формана–Риччи и Оливье–Риччи. Было обнаружено существенное различие в сходимости, по-бинам, для разницы гистограмм кривизны при статистическом перемешивании в группах больных шизофренией и группы нормы – для больных пациентов она существенно ниже, что подтверждается гетерогенностью симптомов заболевания.

Симптомы шизофрении могут объединяться в домены (дименсии), которые присутствуют при различных психотических расстройствах и могут

сосуществовать у одного и того же пациента в различных качественных и/или количественных сочетаниях, включающие: позитивные расстройства или искажение восприятия реальности (бред и галлюцинации), негативные расстройства (абулию/апатию, ангедонию, асоциальность и снижение выразительности эмоций), психомоторные нарушения (в виде кататонических феноменов), а также когнитивные и аффективные нарушения и явления дезорганизации (включая формальные расстройства мышления). Такая кластеризация должна проявляться в геометрии соответствующих графов. Поэтому, в дальнейшем планируется на данной выборке испытуемых провести дифференциальное исследование особенностей структурных коннектомов головного мозга в зависимости от выраженности и тяжести доменов симптоматики, а также сравнить особенности структурных и функциональных коннектомов в контексте дискретной римановой геометрии. Интересно будет изучить динамику кривизны сопутствующей перестройки весов, которая индуцируется потоком Риччи [25]. Результаты, полученные в данной работе, позволяют сделать вывод об огромном потенциале применения методов топологического анализа в исследовании структурной и функциональной организации нейросетей головного мозга и их динамического взаимодействия в нейрокогнитивных процессах.

Исследование выполнено частично за счет гранта Российского научного фонда № 20-15-00299П (расчет данных трактографии). Авторы выражают благодарность Захаровой Н.В. за помощь в организации отбора испытуемых группы больных шизофренией и обеспечении транспортной логистики их перемещения для проведения МРТ сканирования.

Список литературы

1. Watts D.J., Strogatz S.H. Collective dynamics of ‘small-world’networks //nature. – 1998. – Т. 393. – №. 6684. – С. 440–442.
2. Baronchelli A. et al. Networks in cognitive science // Trends in cognitive sciences. – 2013. – Т. 17. – №. 7. – С. 348–360.
3. Granovetter M.S. The strength of weak ties // American journal of sociology. – 1973. – Т. 78. – №. 6. – С. 1360–1380.
4. Kiani N.A., Gomez-Cabrero D., Bianconi G. (ed.). Networks of Networks in Biology: Concepts, Tools and Applications. Cambridge University Press, 2021.
5. Wolfram S. A project to find the fundamental theory of physics // (No Title). – 2020.
6. Bianconi G. Higher-order networks. Cambridge Univ. Press, 2021.
7. Bapat R.B. Graphs and matrices. N.Y.: Springer, 2010. V. 27.
8. Molitierno J.J. Applications of Combinatorial Matrix Theory to Laplacian Matrices of Graphs: Chapman and Hall/CRC. 2016.
9. Chung F.R. K. Spectral graph theory. Amer. Math. Soc., 1997. V. 92.

10. Lim L.H. Hodge Laplacians on graphs //Siam Review. 2020. V. 62. P. 685–715.

11. Lee H. et al. Hole detection in metabolic connectivity of Alzheimer's disease using k− Laplacian // Med. Image Comput. Comput. Assist. Interv. -MICCAI 2014. V.17(Pt 3). P. 297–304.

12. Gu D.X., Saucan E. Classical and Discrete Differential Geometry: Theory, Applications and Algorithms. CRC Press, 2023.

13. Najman L., Romon P. (ed.). Modern approaches to discrete curvature. Springer, 2017. V. 2184.

14. Saucan E. et al. Discrete curvatures and network analysis. // MATCH Comm. in Mathematical and in Computer Chem., 2018. V. 20. P. 605–622.

15. Forman F. Bochner's method for cell complexes and combinatorial Ricci curvature // Discrete and Computational Geometry, 2003. V. 29. P. 323–374,

16. Ollivier Y. Ricci curvature of markov chains on metric spaces // J. Functional Anal., 2009. V. 256. P. 81–864.

17. Villani C. et al. Optimal transport: old and new. Springer, 2009. V 338.

18. Tannenbaum E., et al. Signals and control aspects of optimal mass transport and the Boltzmann entropy //49th IEEE CDC. IEEE, 2010. P. 1885–1890.

19. Sandhu R., et al. Graph curvature for differentiating cancer networks // Scientific Reports, 2015. V. 5. P. 1–13.

20. Samal A., et al. Network geometry and market instability // Roy.Soc.Open Science, 2021.V. 8 P.201734.

21. Bullmore E., Sporns O. Complex brain networks: graph theoretical analysis of structural and functional systems //Nature reviews neuroscience. 2009. V. 10. P. 186–198.

22. Berger M. A panoramic view of Riemannian geometry. Springer. 2003.

23. Samal A. et al. Comparative analysis of two discretizations of Ricci curvature for complex networks //Scientific reports. 2018. V. 8. P. 8650.

24. Saucan E. Discrete Morse Theory, Persistent Homology and Forman-Ricci Curvature // Mathematics, Computation and Geometry of Data, 2002. № 2.

25. Ni C.C. et al. Community detection on networks with Ricci flow //Scientific reports. 2019. V. 9. P. 9984.

Секция

Теория нейронных сетей

З.М. ШИБЗУХОВ
Московский государственный педагогический университет
intellimath@mail.ru

НЕКОТОРЫЕ РОБАСТНЫЕ ВАРИАНТЫ МЕТОДА ГЛАВНЫХ КОМПОНЕНТ

Метод главных компонент играет важную роль в декомпозиции исходных данных, который может помогать улучшить качество обучения нейронных сетей. Рассматриваются два новых робастных варианта постановки задачи поиска главных компонент. Они основаны на применении дифференцируемых оценок среднего значения, нечувствительных или мало чувствительных к выбросам. На реальных данных наглядно демонстрируется эффективность предложенного подхода.

Ключевые слова: *линейные нейронные сети, метод главных компонент, робастное среднее*

Введение

Метод главных компонент является одним из методов декомпозиции данных. Классический метод главных компонент первоначально рассматривался как задача наилучшей аппроксимации конечного множества точек прямыми и плоскостями [1]. Представление обучающих данных в базисе главных компонент способствует повышению надежности метода обратного распространения ошибки в процедуре поиске глобального минимума квадратичной функции ошибки нейронной сети из линейных элементов [2].

В машинном обучении метод главных компонент часто используется как метод сокращения размерности входных данных. Однако, если часть данных существенно искажена, то неизбежно также существенно искажаются результаты работы классического метода (Рис. 1). Обзор классических и робастных методов главных компонент можно найти в [3]. При обучении нейронных сетей довольно часто переход к главным компонентам помогает улучшить результаты обучения [4].

В настоящей работе предлагаются два новых робастных варианта постановки задачи поиска главных компонент. Они основаны на применении дифференцируемых оценок среднего значения, нечувствительных или мало чувствительных к выбросам. Предлагаемый подход в принципе позволяет преодолевать влияние выбросов. Ниже описывается классический и новые робастные варианты метода главных компонент. На реальных данных наглядно демонстрируется эффективность предложенного подхода.

Рис. 1. Пример влияния выбросов

Классический метод решения задачи

Решается задача поиска вектор центра a_0 и ортонормированный базис $a_1, \dots, a_m$ m-мерной гиперплоскости в R^n, такой что сумма квадратов Евклидовых расстояний до нее от точек $x_1, \dots, x_N$ минимальна:

$$\sum_{k=1}^{N}\left(\| x_k - a_0 \|^2 - \sum_{j=1}^{m}\left(x_k - a_0, a_j\right)^2\right) \to \min.$$

Решение этой задачи редуцируется к цепочке задач, в которых последовательно находятся векторы $a_0, a_1, \dots, a_m$.

Вектор a_0 находится, как решение задачи:

$$a_0 = \arg\min_{a \in R^n} \sum_{k=1}^{N} \| x_k - a \|^2.$$

Ее решение – выборочное среднее: $a_0 = \frac{1}{N}\sum_{k=1}^{N} x_k$.

После нахождения a_0 осуществляется центрирование:

$$x_k \to x_k - a_0, k = 1, \dots, N.$$

Затем последовательно ищутся векторы a_j $(j = 1, \dots, m)$, как решение задачи

$$a_j = \arg\min_{\|a\|=1} \frac{1}{N}\sum_{k=1}^{N} (\| x_k \|^2 - (a, x_k)^2).$$

После нахождения очередного главного компонента a_j осуществляется преобразование:

$$x_k \to x_k - a_j(a_j, x_k).$$

Метод множителей Лагранжа сводит нашу задачу к следующей задаче

$$a_j, \lambda_j = \operatorname{argmin}_{a,\lambda} \left\{ \frac{1}{N}\sum_{k=1}^{N} (\| x_k \|^2 - (a, x_k)^2) + \lambda(\| a \|^2 - 1) \right\}.$$

Так как

$$\frac{1}{N}\sum_{k=1}^{N} (a, x_k)^2 = \frac{1}{N}(Xa)^\top (Xa) = \frac{1}{N} a^\top (X^\top X) a = a^\top S a,$$

где X – матрица, составленная из строк $x_1, \dots, x_N$, $S = \frac{1}{N} X^\top X$ – ковариационная матрица. Тогда в соответствии с необходимым условием экстремума a_j и λ_j удовлетворяют следующим уравнениям:

$$S a_j = \lambda_j a_j$$
$$\| a_j \| = 1.$$

То есть решения задают ортонормированные собственные векторы и собственные числа матрицы S.

Для поиска a_j можно применить итерационную процедуру:

$$a^{t+1} = \frac{1}{\lambda^t}(S a^t), \qquad \lambda^t = \frac{(a^t)^\top S a^t}{(a^t, a^t)}.$$

Робастная постановка и метод решения задачи

Предлагаемая робастная постановка задачи предполагает замену задачу минимизации

$$Q(a) = \frac{1}{N}\sum_{k=1}^{N} \Phi_k(a)$$

на задачу минимизации

$$Q_M(a) = M\{\Phi_1(a), \dots, \Phi_N(a)\},$$

где $M\{z_1, \dots, z_N\}$ – дифференцируемая оценка среднего значения, нечувствительная или малочувствительная к выбросам [5, 6]. Такая постановка задачи может позволить существенно уменьшить влияние выбросов.

Робастный вариант постановки задачи поиска a_0 принимает вид:

$$a_0 = \arg\min_{a \in R^n} M\{\| x_1 - a \|^2, \dots, \| x_N - a \|^2\}.$$

Она сводится к решению уравнения

$$a = \sum_{k=1}^{N} \frac{\partial M\{\| x_1 - a_0 \|^2, \dots, \| x_N - a_0 \|^2\}}{\partial z_k} x_k,$$

которое можно решить, используя следующую итерационную процедуру:

$$a^{t+1} = \sum_{k=1}^{N} v_k^t x_k,$$

где

$$v_k^t = \frac{\partial M\{\| x_1 - a^t \|^2, \dots, \| x_N - a^t \|^2\}}{\partial z_k}.$$

После нахождения a_0 также осуществляется центрирование:

$$x_k \to x_k - a_0, k = 1, \dots, N.$$

Робастный вариант задачи поиска a_j принимает следующий вид:

$$a_j = \arg\min_{\|a\|=1} M\{\| x_1 \|^2 - (a, x_1)^2, \dots, \| x_N \|^2 - (a, x_N)^2).$$

При помощи метода итеративного перевзвешивания ее решение также можно свести к цепочке задач:

$$a_j^{t+1} = \arg\min_{\|a\|=1} \sum_{k=1}^{N} v_k^t (\| x_k \|^2 - (a, x_k)^2)$$

со следующими значениями весов точек

$$v_k^t = \frac{\partial M\{\| x_1 \|^2 - (a^t, x_1)^2, \dots, \| x_N \|^2 - (a^t, x_N)^2)}{\partial z_k}.$$

Во всех случаях $v_1^t + \dots + v_N^t = 1$, т.к. в силу своего задания

$$\sum_{k=1}^{N} \frac{\partial M\{z_1, \dots, z_N\}}{\partial z_k} = 1.$$

Эта задача представляет собой взвешенный вариант первоначальной задачи поиска a_j в рамках классической постановки задачи.

Матрица ковариации принимает вид:

$$S^t = X^\top \begin{pmatrix} v_1^t & \cdots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \cdots & v_N^t \end{pmatrix} X.$$

Векторы a_j^{t+1} и λ^{t+1} являются решением системы:

$$S^t a = \lambda a$$
$$\| a \|^2 = 1.$$

Для поиска a_j и λ применяется итерационная процедура:

$$a^{t+1} = \frac{1}{\lambda^t}(S^t a^t), \qquad \lambda^t = \frac{(a^t)^\top S^t a^t}{(a^t, a^t)}.$$

Робастная оценка матрицы ковариации

Еще один робастный метод, концептуально близкий к предложенному выше, основан на робастной оценке матрицы ковариации. Он базируется на предположении, что данные представляются выборку из многомерного нормального распределения с плотностью вероятности

$$p(x; c, S) = \frac{1}{(2\pi)^{n/2}|S)^{1/2}} e^{-\frac{1}{2}(x-c)^\top S^{-1}(x-c)},$$

где c – центр; S – ковариационная матрица. Задача поиска c и S на основе принципа максимума функции правдоподобия

$$L(c, S) = \prod_{k=1}^{N} p\,(x_k; c, S)$$

сводится к задаче минимизации функционала

$$Q(c, S) = \ln|S) + \frac{1}{N}\sum_{k=1}^{N} \| x_k - c \|_S,$$

где $\| x - c \|_S = (x - c)^\top S^{-1}(x - c)$ – расстояние Махаланобиса.

Ее решение дает известную формулу для ковариационной матрицы

$$S = \frac{1}{N}\sum_{k=1}^{N} (x_k - c)^\top (x_k - c),$$

где $c = \frac{1}{N}\sum_{k=1}^{N} x_k$.

Робастная постановка задачи получается в результате замены среднего арифметического в определении Q на дифференцируемую оценку среднего, нечувствительную к выбросам:

$$Q(c, S) = \ln|S) + M\{\| x_1 - c \|_S, \dots, \| x_N - c \|_S\}.$$

Центр c является решением нелинейного уравнения

$$c = \sum_{k=1}^{N} \frac{\partial M}{\partial z_k} x_k,$$

а матрица S является решением нелинейного матричного уравнения:

$$S = \sum_{k=1}^{N} \frac{\partial M}{\partial z_k} (x_k - c)^\top (x_k - c),$$

где $z_k = \| x_k - c \|_S$.

Положение центра при заданной матрице S можно вычислить приближенно при помощи итерационной процедуры MPCA_c($c^0; S$):

1. $t = 0$.
2. Шаг t. Вычисляется

$$c^{t+1} = \sum_{k=1}^{N} \frac{\partial M\{z_1^t, \dots, z_N^t\}}{\partial z_k} x_k,$$

где $z_k^t = \| x_k - c^t \|_S$.

3. Если выполняется критерий останова:

$$\left| Q(c^{t+1}, S) - Q(c^t, S) \right| < \varepsilon,$$

то процедура завершается, иначе $t = t + 1$ и шаг 2.

Матрица ковариации при заданном положении центра c вычисляется при помощи итерационной процедуры MPCA_S($c; S^0$):

1. $t = 0$.
2. Шаг t. Вычисляется

$$S^{t+1} = \sum_{k=1}^{N} \frac{\partial M\{z_1^t, \dots, z_N^t\}}{\partial z_k} (x_k - c)^\top (x_k - c),$$

где $z_k^t = \| x_k - c \|_{S^t}$.

3. Если выполняется критерий останова:

$$\left| Q(c, S^{t+1}) - Q(c, S^t) \right| < \varepsilon,$$

то процедура завершается, иначе $t = t + 1$ и шаг 2.

Итоговая итерационная процедура RPCA имеет следующий вид:

1. В начале имеем некоторые c^0 и S^0, $p = 0$.
2. Вычисляется

$$c^{p+1} = \text{RPCA_c}(c^p; S^p).$$

3. Вычисляется

$$S^{p+1} = \text{RPCA_S}(c^{p+1}; S^p).$$

4. Если выполняется критерий останова

$$\left|Q(c^{p+1}, S^{p+1}) - Q(c^p, S^p)\right| < \varepsilon,$$

то процедура завершается, иначе 2.

После нахождения матрицы S для нахождения главных компонентов $a_1, \dots, a_n$ применяется стандартная процедура поиска собственных чисел и векторов S.

Примеры

Для экспериментального подтверждения эффективности предложенного здесь подхода рассматриваются примеры применения классического и робастного методов главных компонент для нескольких наборов данных. В робастном варианте используется следующая функция оценки среднего значения – цензурированное среднее арифметическое:

$$WP_\alpha\{z_1, \dots, z_N\} = \frac{1}{N}\sum_{k=1}^{N} \min(z_k, \overline{z}_\alpha),$$

где $0 < \alpha < 1$,

$$\overline{z}_\alpha = \underset{u}{\operatorname{argmin}} \sum_{k=1}^{N} \rho_\alpha(z_k - u),$$

$$\rho_\alpha(r) = \begin{cases} (1-\alpha)\rho(r), & \text{если } r < 0 \\ 0, & \text{если } r = 0 \\ \alpha\rho(r), & \text{если } r > 0, \end{cases}$$

а $\rho(r) = \sqrt{\varepsilon^2 + r^2}$. При этом

$$\frac{\partial WM_\alpha}{\partial z_k} = \begin{cases} \left(\frac{1}{M} + \frac{m}{M}\right)\frac{\partial \overline{z}_\alpha}{\partial z_k}, & \text{если } z_k < \overline{z}_\alpha \\ \frac{m}{M}\frac{\partial \overline{z}_\alpha}{\partial z_k}, & \text{если } z_k \geq \overline{z}_\alpha \end{cases}$$

Для нахождения $\overline{z}_\alpha$ применяется итерационная процедура

$$u^{t+1} = \frac{\sum_{k=1}^{N} \varphi(z_k - u^t) z_k}{\sum_{k=1}^{N} \varphi(z_k - u^t)},$$

где $\varphi(r) = \rho'_\alpha(r)/r$.

Набор данных starsCYG

Рассмотрим набор данных для построения диаграммы Герцшпрунга-Рассела звездного кластера CYG OB1 [7], который описывает зависимость между логарифмом светимости (log.light) и логарифмом температуры (log.Te) звезд. На рис. 2 есть 7 точек, которые можно отнести к выбросам. Применение классического метода компонент дает векторы главных компонент повернутыми против часовой стрелки в сторону выбросов. Применение обоих робастных метода главных компонент ($\alpha = 0.87$, $\varepsilon = 0.001$) позволяет найти несмещенное положение центра и главные компоненты, которые не отклоняются под влиянием выбросов.

Рис. 2. Набор данных starsCYG

Набор данных HIP_stars

Рассмотрим набор данных для построения диаграммы для звезд из набора данных [8]. На рис. 3 изображена проекция на пару параметров Vmag и B-V. Классический метод главных компонент дает смещенные

главные компоненты для данной проекции. Предложенные робастные методы главных компонент ($\alpha = 0.95$, $\varepsilon = 0.001$) позволяют преодолеть влияние выбросов.

Рис. 3. Набор данных HIP_stars

Заключение

Робастные варианты постановки задачи поиска главных компонент, основанные на минимизации дифференцируемых оценок среднего, которые могут быть существенно более устойчивы к выбросам, в принципе позволяют находить несмещенные векторы главных компонент. Показатель α в сглаженной оценке квантиля примерно соответствует доле данных, которые не являются выбросами (более точное значение находится экспериментально в ее окрестности). Первый робастный метод позволяет идентифицировать выбросы при помощи анализа эмпирического распределения расстояний до прямых, проходящих через центр a_0, вдоль векторов главных компонент. Второй робастный метод также позволяет идентифицировать выбросы путем анализа эмпирического распределения расстояний Махаланобиса от центра до всех точек. Он также интересен тем, что после нахождения робастного варианта ковариационной матрицы S можно применять стандартные алгоритмы метода главных компонент. Первый робастный вариант не использует операции обращения матрицы, а второй метод использует, что ограничивает его применение для данных большой размерности. Первый метод также более удобен, если необходимо найти только малую часть главных компонент.

Список литературы

1. Pearson K. On lines and planes of closest fit to systems of points in space. Philosophical Magazine. 1901. Vol. 2. P. 559–572.

2. Baldi P., Hornik R. Neural Networks and Principial Component Analysis: Learning from Examples Without Local Minima. // Neural Networks. 1989. Vol. 2. P. 53–58.

3. Jolliffe I.T. Principial Component Analysis. 2002. Springer International Publishing.

4. Mahmud F., Afroge S., Mamu M.A., Matin A. PCA and back-propagation neural network based face recognition system. In: 18th International Conference on Computer and Information Technology (ICCIT). Dhaka, Bangladesh. 2015. P. 582-587.

5. Shibzukhov Z.M. Machine Learning Based on the Principle of Minimizing Robust Mean Estimates. In: Brain-Inspired Cognitive Architectures for Artificial Intelligence: BICAAI 2020. Springer International Publishing. 2020. P. 472–477.

6. Shibzukhov Z.M. Minimizing Robust Estimates of Sums of Parameterized Functions Journal of Mathematical Sciences. Springer Science and Business Media LLC. 2022. Vol. 260. P. 249–264

7. Rousseeuw P.J., Leroy A.M. Robust Regression and Outlier Detection. Wiley. 1987. P. 27, table 3.

8. Dataset Hipparcos. https://www.astrostatistics.psu.edu/datasets/HIP_star.html

Д.О. РОДИОНОВ

Московский государственный университет им. М.В. Ломоносова

danila.rodionov@math.su.ru

РАЦИОНАЛЬНАЯ АППРОКСИМАЦИЯ ЯДРА СВЕРТКИ РЕШЕНИЯ ВОЛНОВОГО УРАВНЕНИЯ В КАНАЛЕ С ПОМОЩЬЮ НЕЙРОННОЙ СЕТИ ДЛЯ ПОСТРОЕНИЯ ПРОЗРАЧНЫХ ГРАНИЧНЫХ УСЛОВИЙ

Рассматривается задача построения рациональной аппроксимации ядра свертки (суммы экспонент) с помощью нейронной сети с целью построения прозрачных граничных условий для неограниченной области. Представлен класс функций, допустимых как функций активации нейронной сети, в терминах образов преобразования Фурье. Предложена и реализована модель построения аппроксимации на основе нейронной сети, проведен её параметрический анализ, изучены приложения в области классификации изображений.

Ключевые слова: *классификация изображений, оптимизация, граничные условия, рациональная аппроксимация.*

Введение

В работе представлены результаты применения нейронных сетей для получения аппроксимации типа Паде для ядра свертки решения волнового уравнения в канале с целью построения прозрачных граничных условий. Оценка эффективности алгоритма проводится на основе сравнения с реализованным библиотечным методом построения рациональной аппроксимации. Этот алгоритм предназначен для построения аппроксимации Паде с использованием входных данных в виде вектора коэффициентов разложения функции в ряд Тейлора в окрестности нуля посредством решения системы линейных уравнений. Среди большого количества методов построения искусственных граничных условий на открытых границах особое место занимают так называемые прозрачные граничные условия (ПГУ), основанные на преобразовании Лапласа по времени и аппроксимация ядра свертки полученного точного граничного условия суммой экспонент. В пространстве изображений преобразования Лапласа ей соответствует сумма полюсов, которая после простейших алгебраических преобразований обращается в рациональную функцию. Одним из алгоритмов подбора коэффициентов в данной задаче может быть решение системы линейных уравнений, однако по ряду причин этот метод не всегда является оптимальным. Альтернативой является создание архитектуры нейронной сети, реализующей заданную функцию, суть обучения которой - поиск параметров для минимизации некоторого функционала. В общем случае для архитектур с заданным классом функций существование такого решения гарантируется теоремой Цыбенко. Таким образом для заданной сетки и известных значений ядра численная аппроксимация может быть получена в явном виде, что является очевидным преимуществом перед стандартным алгоритмом, основанном на разложении данной функции в ряд. В процессе исследования были проанализированы результаты решения в зависимости от порядка многочлена знаменателя, сложности архитектуры, начальных распределений весов, количества итераций обучения. Для одинаковых порядков знаменателей было также проведено сравнение с библиотечным методом, в ходе которого было выяснено, что уже для $n = 5$ точность, демонстрируемая нейронной сетью, превосходит вышеуказанный метод более чем в два раза. Таким образом, применение нейронной сети позволило получить решение с высокой степенью точности, превосходящей уже существующий алгоритм. В дальнейшем планируется провести анализ оптимальной глубины сети и сравнить результаты с другими существующими алгоритмами.

Постановка аналитической задачи

Более подробно с аналитической постановкой задачи можно ознакомиться в работе [1], мы изложим лишь самые необходимые шаги.

Рассмотрим задачу о распространении волн в бесконечном канале кругового сечения радиуса a. Будем считать, что ось канала совпадает с осью z цилиндрической системы координат. Будем искать численное решение задачи в конечной подобласти Ω этого канала, которая ограничена искусственными границами − плоскостями $z = z_L$ и $z = z_R$. Движение описывается волновым уравнением: $\frac{1}{c^2}\frac{\partial^2 w}{\partial t^2} = \Delta w$, где c − скорость звука среды, t − время, Δ − оператор Лапласа. Граничные условия при $r = a$: $\alpha\frac{\partial w}{\partial r} + \beta w = 0,\ |\alpha| + |\beta| \neq 0.$ На границах $z = z_L$ и $z = z_R$ требуется поставить такие граничные условия, чтобы решение задачи в Ω совпадало с решением во всей неограниченной области.

Алгоритм получения точного аналитического вида граничных условий строится следующим образом: рассмотрим разложение решения w по собственным функциям оператора Лапласа в круге радиуса a:

$$w(r,\ \varphi,\ z,\ t) = \sum_{n=0}^{\infty}\sum_{k=1}^{\infty}\sum_{m=1}^{2}\psi_{k,n,m}(r,\ \varphi)w_{k,n,m}(z,\ t).$$

При этом выполняется соотношение $\Delta\psi_{k,n,m} + \lambda_{k,n}\psi_{k,n,m} = 0.$ Подставим разложение по собственным функциям Лапласа функции w в исходное волновое уравнение. Тогда получим следующее соотношение для коэффициентов Фурье: $\frac{1}{c^2}\frac{\partial^2 w_{k,n,m}}{\partial t^2} = \frac{\partial^2 w_{k,n,m}}{\partial z^2} - \lambda_{k,n}w_{k,n,m}$. Рассмотрим замену переменных: $\overline{t} = c\lambda_{k,n}t,\ \overline{z} = \lambda_{k,n}z$. Тогда полученное уравнение для коэффициентов Фурье преобразуется в уравнение вида $\frac{\partial^2 u}{\partial t^2} = u'' - u$, где $u = w_{k,n,m}$ − амплитуда соответствующей гармоники, u'' − вторая производная по пространственной координате. Для этого уравнения и будем строить ПГУ.

После применения преобразования Лапласа последнее уравнение преобразуется в уравнение вида $U'' = (s^2 + 1)U$ или же $U' = PU$, где функция P находится из подстановки в уравнение второго порядка.

Тогда $P = \pm\sqrt{s^2 + 1}$ в силу ограниченности на правом и левом концах. Выделим наибольшие степени по переменной s функции P перед тем, как

перейти к оригиналу: $P(s) = p_1 s + p_0 + F(s)$. Для задачи с постоянными коэффициентами $F(s) = \sqrt{s^2 + 1} - s$.

Теперь наша задача − построить аппроксимацию $F(s)$ с помощью нейронной сети. Аналитически это выражение будет являть собой сумму экспонент, которая в пространстве изображений даст сумму полюсов, которую, очевидно, можно привести к виду $\tilde{F}(s) = \frac{Q_{m-1}(s)}{P_m(s)}$, где $Q_{m-1}(s)$ и $P_m(s)$ – полиномы степеней соответствующих индексов.

Изучим вопрос существования аппроксимации и сведения задачи оптимизации к построению нейронной сети.

Одним из методов построения аппроксимации типа Паде является следующий алгоритм, основанный на равенстве производных самой функции и её аппроксиманта. Представим функцию $F(s)$ в виде своего ряда Тейлора: $F(s) = \sum_{n=0}^{\infty} c_n s^n$. Тогда пользуясь этим разложением, получим следующее соотношение $\frac{Q_{m-1}(s)}{P_m(s)} = \sum_{n=0}^{\infty} c_n s^n$.

Домножая обе части на $P_m(s)$и приравнивая коэффициенты при s^k получаем систему линейных алгебраических уравнений на коэффициенты полиномов.

Однако этот метод по ряду причин далеко не всегда является удовлетворительным. Альтернативой является решение оптимизационной задачи, а именно - поиск минимума некоторого функционала относительно набора параметров. В частности, пусть a и b − векторы коэффициентов некоторых полиномов. Тогда задачу можно сформулировать следующим образом: при условии $\sum_{k=0}^{M} b_k x^k > 0$ для всех x из некоторого компакта $I \subset \mathbb{R}$, $a \in \mathbb{R}^{m-1}$, $b \in \mathbb{R}^m$, найти

$$\inf \quad \max_{x \in R} \left| F(x) - \frac{\sum_{j=0}^{M-1} a_j x^j}{\sum_{k=0}^{M} b_k x^k} \right|.$$

Условие строгой положительности $\sum_{k=0}^{m} b_k x^k > 0$ необходимо для корректной постановки задачи оптимизации. Однако это условие не является условием дополнительной жесткости, что не позволяет нам прибегнуть к формализму условий Каруша-Куна-Таккера. Для устранения этой проблемы обратимся к утверждению из выпуклого анализа [2, лемма 1.4], гарантирующее существование решения задачи: Пусть A − некоторое множество, и $f(x, y)$ выпуклая по y функция. Тогда $g(x) = \sup_{y \in A} f(x, y)$ является выпуклой по x.

По условию множество I − компактно, поэтому решение оптимизационной задачи существует.

Теперь обратимся к параметрическому описанию классов нейронных сетей в задачах аппроксимации как функциональных подпространств.

Существование аппроксимации с помощью параметрических семейств функций, реализуемых нейронной сетью заданной архитектурой обусловлено теоремой Цыбенко или универсальной теоремой об аппроксимации. Оно сужает класс активационных функций до семейства сигмоидальных функций, которые, в частности, используются в задачах классификации (‘сигмоида’ или её многомерный вариант − ‘softmax’). Сформулируем теорему для этого класса функций:

Пусть φ − некоторая непрерывная сигмоидальная функция, $f(x)$ − произвольная непрерывная заданная на некотором компактном в $\mathbb{R}^n$множестве K. Тогда для любого положительного $\epsilon > 0$ найдется такой набор векторов $w_1, \ldots, w_n$, θ, α, функция $G(x) = \sum_{i=0}^{n} \alpha_i f(w_i x + \theta_i)$, что для всякого $x \in \mathbb{R}^n$ выполнено $|G(x) - f(x)| < \epsilon$. 1.

Несмотря на то, что множество сигмоидальных функций всюду плотно в пространстве непрерывных на компакте функций ([3]), ограничение класса активаций значительно влияет на конечный вид аппроксиманта. В частности, построенная через сигмоидальные функции рациональная функция будет рациональной не в общем определении, а только по экспонентам. В связи с этим расширим класс функций активации и введем понятие функций Таубера-Виннера.

Функцию $g\colon A \to \mathbb{R}$ будем называть функцией Таубера-Виннера (**TW**), если линейные комбинации вида $\sum_{j=0}^{M} c_j\, g(\lambda_j x + \theta_j)$ всюду плотны в пространстве непрерывных функций $C(A)$.

Для содержательного описания этого класса функций нам понадобится следующая теорема (с доказательством можно ознакомиться в [4]):

Пусть $g(x) \in C(A) \cap S'(A)$. Тогда $g(x) \in TW$ если и только если $g(x)$ − не полином.

Теперь мы можем полноценно обобщить универсальную теорему об аппроксимации на класс функций Таубера-Виннера ([4]), а именно:

Пусть $K \subset \mathbb{R}^n$, $U \subset C(K)$ − некоторые компактные множества, $g \in TW$. Тогда для произвольного $\epsilon > 0$ найдутся такие N, $\theta_i \in \mathbb{R}$, $w_i \in \mathbb{R}^n$, $i = 1, \ldots, N$, которые не зависят от $f \in U$ и константы $c_i(f)$, зависящие

от f, что $|f(x) - \sum_{i=1}^{N} c_i(f) f(xw_i + \theta_i)| < \epsilon$ для всех $x \in K$, $f \in U$. При этом $c_i(f)$ являются непрерывными функционалами на U.

Сформулированная таким образом теорема позволяет значительно расширить класс используемых функций для аппроксимации и, в частности, строить аппроксимации в виде рациональных функций.

Перед тем как непосредственно строить модель и лидировать полученный с помощью нее результат необходимо заметить, что методы, с которыми произведено сравнение, периодически демонстрируют результат с очень низкой точностью. Основная причина - наличие особых точек у многолистных точек в области аппроксимации, а также локальности разложения в ряд Тейлора, которое на достаточном отдалении от центра окрестности даёт высокую погрешность.

Теперь спроектируем архитектуру нейронной сети, реализующей рациональную аппроксимацию:

1) парадигма − полносвязная нейронная сеть с количеством слоёв, равным трём;

2) минимизируемый функционал − стандартная функция MSE;

3) функционал для валидации - абсолютная ошибка MAE;

4) итерации обучения − 1000, усреднение градиента проводится по подмножеству мощности 64.

В качестве данных для обучения осмысленно рассмотреть произвольный отрезок $I \in \mathbb{R}$ и равномерную сетку на нём. На вход нейронной сети будем подавать два вектора $P = (1, x, \ldots, x^{m-1})$, $Q = (1, x, \ldots, x^{m})$, где $x \in I$. В качестве выходных данных будем передавать значение функции $F(x)$ в заданной точке x. Как и для любой задачи оптимизации функционала с помощью алгоритма градиентного спуска, необходимо выбрать распределение начального приближения $w_i^{\text{начальное}}$. Несмотря на то, что нормальное распределение $w_i^{\text{начальное}} \sim N\left(0, \sqrt{\frac{2}{n_{in}}}\right)$, где n_{in} − размерность входных данных, демонстрирует высокое качество, этот вопрос требует более глубокого дальнейшего изучения.

Спроектированная нейронная сеть была обучена на нескольких семействах параметров, главным из которых является количество степеней свободы в аппроксимации, то есть - степень знаменателя. Ниже представлены графики зависимости метрик отношения абсолютных ошибок результата алгоритма Pade к результату, полученному с помощью нейронной сети.

Рис. 1. График зависимости отношения абсолютной ошибки алгоритма Pade к абсолютной ошибке нейронной сети в зависимости от порядка знаменателя в метрике L1

Заметим, что на полиномах достаточно низкого порядка нейронная сеть демонстрирует значительно более точный результат.

Рис. 2. График зависимости отношения абсолютной ошибки алгоритма Pade к абсолютной ошибке нейронной сети в зависимости от порядка знаменателя в метрике MSE

Выводы

Предложен и реализован оптимизационный алгоритм построения рациональной аппроксимации ядра свертки волнового уравнения в канале на основе нейронной сети. Алгоритм позволяет повысить точность аппроксимации и в явном виде реализовать рациональную функцию, являющуюся образом ядра после преобразования Лапласа. Продемонстрировано преимущество алгоритма в сравнении с уже существующими.

Программа дальнейших исследований будет включать в себя изучение начальных распределений весов нейронной сети, а также её гиперпараметров, отвечающих за оптимальность решения. Таковыми являются глубина нейронной сети, выбор стратегии обучения и адаптивного алгоритма скорости. Также будут имплементированы рациональные функции активации в задачах Computer Vision, таких как классификация и сегментация изображений. Перспективность этого направления продемонстрирована в [5], где архитектуры на основе рациональной функции активации продемонстрировали свое значительное преимущество и показали наибольшую точность в экспериментах на датасете MNIST.

Список литературы

1. Н.А. Зайцев Прозрачные граничные условия для волнового уравнения в канале кругового сечения// Препринты ИПМ им. М.В. Келдыша УДК 519.651, 519.633.6.
2. Выпуклая оптимизация: учебное пособие // Е.А. Воронцова, Р.Ф. Хильдебранд, А.В. Гасников, Ф.С. Стонякин. М., МФТИ.
3. Cybenko, G. V. Atproximation by Superpositions of a Sigmoidal function// Mathematics of Control Signals and Systems. – 1989. – Т. 2. № 4. – С. 303–314.
4. T.P. Chen and H. Chen, Approximations of continuous functionals by neural networks with application to dynamic systems // IEEE Transactions on Neural Networks (Volume: 4, Issue: 6, November 1993). P. 910–918.
5. Nicolas Boullé, Yuji Nakatsukasa, and Alex Townsend, Rational neural networks, arXiv preprint arXiv:2004.01902 (2020).
6. V. Peiris, N. Sharon, N. Sukhorukova, J. Ugon Generalised rational approximation and its application to improve deep learning classifiers Applied Mathematics and Computation 389, 125560
7. http:// scipy.org
8. http://keras.io

Ю.М. ВИТЮГОВА, А.О. ЕФИТОРОВ, В.Р. ШИРОКИЙ
НИИ ядерной физики им. Д. В. Скобельцына МГУ им. М.В. Ломоносова
vitiugova.im18@physics.msu.ru

СРАВНЕНИЕ МЕТОДОВ ОТБОРА ВХОДНЫХ ПРИЗНАКОВ НА ОСНОВЕ АНАЛИЗА ВЕСОВ НЕЙРОННОЙ СЕТИ

В данной работе проводится сравнительный анализ эффективности различных способов анализа существенности входных признаков для нейронных сетей на примере задачи определения состава газовых смесей по данным полупроводниковых сенсоров. В процессе работы проводились оценка и отбор входных признаков при помощи методов анализа весов нейронной сети и глубокого разложения Тейлора, а также сравнение с референсными методами.

Ключевые слова: *нейронные сети, анализ признаков, методы отбора существенных признаков.*

Введение

Современный этап развития цивилизации характеризуется удешевлением и резким увеличением объёмов данных, получаемых с сенсоров различной природы. Так, в настоящей работе используются данные, полученные с полупроводниковых сенсоров, применяемых для определения концентрации газов в окружающем сенсор воздухе. Подобные данные часто характеризуются высокой размерностью, что затрудняет их обработку и анализ. По этой причине возникает необходимость в использовании подходов для снижения размерности входных данных.

Для решения этой задачи могут использоваться методы анализа существенности входных признаков (АСВП). В данной работе сравнивается эффективность методов АСВП, основанных на анализе весов нейронной сети (НС) – классического метода анализа весов НС (МАВНС) и метода глубокого разложения Тейлора (МГРТ). При использовании НС в качестве модели, решающей искомую задачу, применение подобных методов выглядит наиболее оправданным, что продемонстрировано в настоящей работе. При этом в качестве референсных используются методы, основанные на удалении информации, приносимой тем или иным входным признаком – метод фиксации значений входного признака (МФЗВП) и метод перемешивания значений входного признака (МПЗВП).

Методы понижения размерности входных данных

Под размерностью конкретного набора данных будем понимать минимальное значение d из возможных значений размерности, при котором произвольный набор из N точек d-мерного пространства успешно решает задачу с точностью не хуже, чем исходный набор из N точек k-мерного пространства. Проблема понижения размерности данных возникает, когда система эффективно работает в пространстве размерности не выше d, но размерность пространства входных данных k выше или существенно выше. Для понижения размерности выделяют две взаимодополняющие группы методов, которые применяются в области понижения размерности данных [1]: отбор наиболее существенных входных признаков (ВП) из полного набора имеющихся (Feature Selection) и конструирование новых ВП на базе существующего набора (Feature Extraction). В данной работе рассматриваются методы АСВП, которые затем используются для отбора наиболее существенных ВП. Существует следующая общепринятая классификация методов отбора ВП [2]:

1. *Фильтры (Filters)* – это методы, оценивающие существенность каждого из ВП, на основании только характеристик самих данных.
2. *Обертки (Wrappers)* – методы, основанные на обучении целевого алгоритма решения задачи на подмножествах исходного набора ВП и выборе подмножества, удовлетворяющего заданному критерию.
3. *Встроенные методы (Embedded)* – методы, для которых отбор ВП естественным образом встроен в сами алгоритмы обучения.

Для оценки существенности ВП в наборе данных существует множество алгоритмов, основанных на корреляционном анализе [3], кросс-энтропийном анализе [4], линейной регрессии [5], [6], нейронной сети с общей регрессией [7], анализе весов полносвязной нейронной сети и др. В данной работе мы остановимся только на последнем классе методов – анализе весов нейронной сети, сравнивая классический метод АВНС [8] с более современным МГРТ и с более простыми референсными алгоритмами оценки.

Метод перемешивания значений входных признаков

Метод перемешивания значений входных признаков (МПЗВП) представляет собой метод для оценки важности признаков в модели НС путем нарушения отношения между признаком и целевой переменной с измерением изменения качества модели. МПЗВП может быть полезен для отбрасывания неинформативных или слабо коррелирующих с целевой переменной признаков, которые могут негативно влиять на качество модели.

Для каждого признака поэтапно выполняются следующие операции:

1. Случайным образом осуществляется перестановка значений признака x_j в наборе данных, нарушая зависимость между признаком и целевой переменной, с получением нового квази-признака x_j^{shuf}.

2. Производится вычисление значение существенности признака с помощью статистических метрик качества:

$$R_{ik} = MAE\left(y_k\left(x_1, \dots x_j^{shuf}, \dots x_n\right), d_k\right).$$

Здесь y_k – ответ сети, d_k – истинное значение целевой переменной.

3. Рассчитывается оценка силы влияния признака с помощью измерения разницы между качеством работы модели на измененной выборке и качеством работы модели на оригинальной выборке.

Метод фиксации значений входных признаков

Метод фиксации значений входных признаков (МФЗВП) является также одним из методов для оценки существенности входного признака при его изменении. Алгоритм состоит из следующих применяемых поэтапно операций:

1. Фиксация значения одного из признаков x_j – например, на уровне, равном среднему значению x_j^{mean} этого признака на тренировочном наборе данных.

2. Производится вычисление значение существенности признака с помощью статистических метрик качества:

$$R_{ik} = MAE\left(y_k\left(x_1, \dots x_j^{mean}, \dots x_n\right), d_k\right).$$

Здесь y_k – ответ сети, d_k – истинное значение целевой переменной.

3. Рассчитывается оценка силы влияния признака с помощью измерения разницы между качеством работы модели на измененной выборке и качеством работы модели на оригинальной выборке.

Метод анализа весов нейронной сети

Методы анализа весов нейронной сети (МАВНС) – это семейство алгоритмов, которые позволяют оценить существенность входных признаков на основе весов обученного многослойного персептрона. Существуют модификации данного семейства, описанные в работах [8–10]. Рассмотрим классический метод [11], используемый в данной работе.

Значения существенности входного признака с номером i относительно выходного признака с номером k оцениваются следующим образом:

$$R_{ik} = \frac{\sum_{j=1}^{M} |w_{ij} w_{jk}|}{\sum_{i=1}^{N} \sum_{j=1}^{M} |w_{ij} w_{jk}|}.$$

При этом значения R_{ik} являются неотрицательными и сумма значений существенности всех признаков равна единице $\sum_{i=1}^{N} R_{ik} = 1$. Введены следующие обозначения: N – число нейронов входного слоя сети, совпадает с размерностью входных данных; M – число нейронов скрытого слоя сети; w_{ij} – элемент матрицы весов скрытого слоя сети (значение веса между i-м нейроном входного слоя и j-м нейроном скрытого слоя); w_{jk} – элемент матрицы весов выходного слоя сети (значение веса между j-м нейроном скрытого слоя и k-м нейроном выходного слоя).

Метод глубокого разложения Тейлора

Метод глубокого разложения Тейлора (МГРТ) [12] помогает разобраться в нелинейных решениях НС с помощью метода декомпозиции решения, осуществляемого путем обратного распространения, основанного на разложении функции выхода НС по формуле Тейлора по активациям нейронов входного слоя сети (рис. 1).

Рис. 1. Графическая интерпретация перераспределения локальной функции R

При обратном распространении вычисляется первый порядок приближения функции выхода по формуле Тейлора:

$$f(x) = f(\tilde{x}) + \frac{f\prime(\tilde{x})}{1!}(x - \tilde{x}) = f(\tilde{x}) + \left.\frac{\partial f}{\partial x}\right|_{x=\tilde{x}} (x - \tilde{x}),$$

где корневая точка разложения является точкой $f(\tilde{x}) = 0$.

Выполнив разложение функции выхода НС по формуле Тейлора, приравняем прогнозируемый результат $f(x) = \sum_{i=1}^{k} R_k$ к функции релевантности. При этом релевантность для нейронов выходного слоя может быть выражена в терминах релевантности нейронов скрытого слоя: $R_k = \sum_{j}^{m} R_j$ (рис. 2).

Рис. 2. Распределение функции релевантности выходного слоя

Получим, что перераспределенные в обратном направлении функции релевантности R_j могут быть записаны следующим образом:

$$R_{j1} = \frac{\partial R_k}{\partial x_{j1}}\bigg|_{(\tilde{x}_1)} (x_{j1} - \tilde{x}_{j1}),$$

$$R_j = \sum_{j=1}^{m} \frac{\partial R_k}{\partial x_j}\bigg|_{(\tilde{x}_j)} (x_j - \tilde{x}_j).$$

Аналогично для i-го слоя:

$$\sum_i R_i = \sum_i \sum_j \frac{\partial R_j}{\partial x_i}\bigg|_{(\tilde{x}_i)} (x_i - \tilde{x}_i).$$

В итоге метод с помощью значения локальной функции релевантности R_i входного слоя определяет значения существенности входных признаков, с помощью которых создает тепловую карту, объясняющую, почему классификатор НС выбрал конкретное решение, то есть тепловая карта является результатом глубокого разложения Тейлора функции выхода НС (рис. 3).

Рис. 3. Распределение функции релевантности входного слоя

Результаты

В данной работе были использованы данные четырех полупроводниковых сенсоров (датчиков)[1], которые представляли собой измерения для атмосферного воздуха и воздуха с примесью пропана или водорода в концентрациях от 30 до 550 ppm. Один цикл модуляции температуры датчика длился 60 с, включая этап нагрева – 35 с и этап охлаждения – 15 с, всего 550 точек, которые представляли собой значения сопротивления датчика и использовались в качестве ВП НС. Два выходных признака – уровни концентраций пропана и водорода в анализируемой среде.

Производилось разделение исходного набора данных (4366 примеров) на тренировочный набор – 60 % от полного набора данных, тестовый и валидационный наборы – по 20 %.

В качестве статистической модели использовалась НС следующей конфигурации, реализованная в библиотеке PyTorch, которая обучалась путем минимизации функции потерь с помощью градиентного спуска:

- Многослойный персептрон с одним скрытым слоем.
- Скрытый слой – 32 нейрона, сигмоидальная передаточная функция, скорость обучения $r = 0.001$.
- Выходной слой – 2 нейрона, линейная передаточная функция, скорость обучения $r = 0.001$.
- Критерий остановки обучения – невозрастание суммарной квадратичной ошибки на валидационном наборе за 1000 эпох.

В таблице приведены результаты статистических показателей моделей НС для задачи нелинейной регрессии по определению значений концентраций газов водорода и пропана, указывающие на эффективность использования различных методов АСВП с последующим применением отбора 50 % наиболее существенных признаков. Доля отбираемых признаков для каждого метода в данной работе не оптимизировалась; это предполагается сделать при продолжении работ. Погрешность вычислена как стандартное отклонение по 5 запускам каждого метода. Видно, что при таком критерии отбора признаков различия результатов между методами лежат в пределах статистического разброса между запусками каждого метода.

Минимальные значения среднеквадратичной ошибки (СКО) при оценке качества работы НС получились при отборе признаков с помощью МАВНС и МГРТ, что подтверждает важность проведения отбора и оценки входных признаков для улучшения качества модели.

---

[1] Данные получены в лаборатории химии и физики полупроводниковых и сенсорных материалов на химическом факультете МГУ под руководством с.н.с., к.х.н. В.В. Кривецкого.

Таблица

Значения СКО и R^2 для моделей НС с разными методами отбора

Метод отбора	СКО, ppm	R^2	СКО/диапазон, %
Без отбора	25,92±1,12	0,755±0,017	1,62±0,07
МФЗВП	26,40±3,52	0,752±0,028	1,65±0,22
МПЗВП	25,44±5,44	0,763±0,045	1,59±0,34
МАВНС	25,12±4,80	0,767±0,034	1,57±0,30
МГРТ	24,32±3,04	0,774±0,025	1,52±0,19

Понижение значений СКО для МГРТ объясняется тем, что данный метод опирается на локальную аппроксимацию функциональной зависимости признаков.

После отбора признаков архитектура НС становится менее сложной и менее подвержена переобучению, что приводит к улучшению результатов после применения МАВНС.

МПЗВП показал улучшение результатов по сравнению с исходными данными, но он оказался менее эффективным, чем МАВНС и МГРТ. Данный подход не гарантирует, что перемешивание значений действительно выявит важность признака, и менее стабилен, чем другие методы.

МФЗВП показал наихудшие результаты. Это можно объяснить тем, что фиксация значений на определенном наборе входных данных может не обязательно обеспечить активность самых важных признаков, поскольку такая фиксация может быть неинформативной или случайной.

На рис. 4–7 визуализированы значения статистических показателей существенностей входных признаков: среднее значение, медианное значение, первый и третий квартили, минимальное и максимальное значение.

Анализируя 1-й и 3-й квартили значений существенности, можно оценить распределение значений. Если разница между 1-м и 3-м квартилями небольшая, это указывает на то, что значения существенности в большей степени сосредоточены вокруг среднего значения и, следовательно, признак более стабильный. Если разница велика, то распределение значений широкое, что указывает на возможную нестабильность признака.

Наблюдение за минимальными и максимальными значениями значений существенности входных признаков может дать представление о диапазоне изменения значений. Если он большой, это может указывать на то, что существенность признака сильно меняется в зависимости от конкретного процесса выборки или оценки. В то же время признаки с малым диапазоном между минимумом и максимумом могут считаться более стабильными.

Значения существенностей МАВНС и МГРТ имеют большую контрастность, что может быть индикатором более точных результатов метода. Они

могут быть эффективными при работе с данными, где существует сложная взаимозависимость между признаками в физических процессах. Кроме того, визуализация может помочь выявить взаимосвязи между признаками.

Рис. 4. Сводные метрики значений существенности входных признаков МГРТ

Рис. 5. Сводные метрики значений существенности входных признаков МАВНС

Рис. 6. Сводные метрики значений существенности входных признаков МПЗВП

Рис. 7. Сводные метрики значений существенности входных признаков МФЗВП

МФЗВП и МПЗВП представляют малоконтрастную картину, значения мало отличаются друг от друга и выглядят случайными. Видимой корреляции между соседними точками нет. Эти методы менее информативны, но могут дать представление о минимальных уровнях значимости.

Таким образом, выбор метода отбора входных признаков в модели зависит от исходных данных и поставленных перед моделью задач. В случае с данными, где важно учитывать взаимосвязь между признаками, следует использовать более сложные методы, основанные на анализе весов НС, такие как МГРТ и МАВНС. Если же данные относительно простые, то МПЗВП или МФЗВП могут быть более эффективными.

Выводы

По результатам работы могут быть сделаны следующие выводы.

1. Статистические параметры лучшего полученного нейросетевого решения задачи определения значений концентрации газов (водород, пропан) в воздухе мегаполиса Москвы на полном наборе признаков на тестовом наборе данных составили: среднеквадратичное отклонение СКО = 25.92±1.12 ppm, коэффициент детерминации R^2 = 0.755±0.017.
2. Отбор 50 % наиболее существенных входных признаков позволяет повысить качество нейросетевого решения. Однако следует оптимизировать долю отбираемых признаков для каждого метода.
3. Методы определения существенности входных признаков, основанные на анализе весов нейронной сети (собственно метод анализа весов и метод глубокого разложения Тейлора) позволяют при отборе 50% признаков добиться более высокого качества решения задачи по сравнению с референсными методами. Наилучшие полученные результаты на тестовом наборе

данных составили: СКО = 24,32±3,04 ppm, R^2 = 0,774±0,025 при отборе с помощью МГРТ; СКО = 25,12±4,80 ppm, R^2 = 0,767±0,034 при использовании алгоритма АВНС. Различие является статистически незначимым.

4. Визуализация значений существенности, полученных при использовании различных методов, может помочь более наглядно представить различия между методами и определить, какие признаки имеют большую или непостоянную значимость.

5. Метод глубокого разложения Тейлора с помощью визуализации показал наиболее контрастную картину, что свидетельствует о его информативности и возможности выявления более сложных зависимостей, включая мультиколлинеарность признаков.

Список литературы

1. Guyon I. et al. Feature Extraction: foundations and applications // Studies in Fuzziness and Soft Computing. 2006. Vol. 207. Chapter 4. P. 119–136.

2. Kohavi R., John G. Wrappers for feature subset selection // Artificial Intelligence. 1997. Vol. 97. Nov 1–2: P. 273–324.

3. Cohen I. et al. Pearson Correlation Coefficient // Noise Reduction in Speech Processing. ISBN 978-3-642-00295-3. Springer Berlin Heidelberg. 2009. P. 1–4.

4. Press W.H., Teukolsky S.A., Vetterling W.T., Flannery B.P. Numerical Recipes in C // The Art of Scientific Cimputing, Cambridge Univercity Press, 1992.

5. Дрейпер Н., Смит Г. Прикладной регрессионный анализ. Издательский дом «Вильямс». 2007. С. 912.

6. Стрижов В.В. Методы индуктивного порождения регрессионных моделей. М.: ВЦ РАН. 2008. С. 55.

7. Specht D.F. A Generalized Regression Neural Network // IEEE Transactions on Neural Networks. 1991. Vol. 2. No. 6. P. 568–576.

8. Gevrey M. , Dimopoulos I., Lek S. Review and comparison of methods to study the contribution of variables in artificial neural network models // Ecological Modelling. 2003. P. 249-264.

9. Linda L. Feature Selection Using Neural Networks with Contribution Measures // Computer Science and Engineering, University of New South Wales. 1995.

10. Warren S. How to measure importance of inputs? // SAS Institute Inc., Cary, NC, USA. ftp://ftp.sas.com/pub/neural/importance.html

11. Гужва А.Г. Разработка методологии и программного комплекса для определения существенности входных признаков при нейросетевом анализе данных. Дисс. канд. физ.-мат. наук, МГУ имени Ломоносова, Москва. 2011.

12. Montavon, G. et al. Explaining nonlinear classification decisions with deep Taylor decomposition // Pattern Recognition. 2017. Vol. 65. P. 211–222.

Секция

Адаптивное поведение и эволюционное моделирование

SAMER EL-KHATIB[1], YURI SKOBTSOV[2], SERGEY RODZIN[1]
[1]Southern Federal University, Russia,
samer_elkhatib@mail.ru, srodzin@yandex.ru
[2]St. Petersburg Polytechnic University, Russia,
ya_skobtsov@list.ru

DETERMINATION OF OPTIMAL HEURISTIC IMAGE SEGMENTATION COEFFICIENTS FOR MODIFIED ANT COLONY OPTIMIZATION METHOD FOR COMPLEXLY STRUCTURED IMAGES

Segmentation is the process of dividing a source image of size M×N into K clusters that are as different from each other as possible and represent objects in the source image. Starting with an initial image in the form of pixels with visual characteristics such as brightness, color, texture, specific size, noise level, contrast and quality, we need to find such marking of image within the available resources to a certain number of K clusters, providing high accuracy and subsequent recognition quality. Complexly structured images are images with a non-deterministic and nonlinear structure composed of many complex elements with important properties. A convenient way to effectively solve the image segmentation problem is to use distributed self-organized systems composed of many agents that interact locally with each other and with the environment to achieve a specific goal. In image processing and computer vision, segmentation remains a difficult problem for many real-time applications and requires further research. Heuristic parameters affect to computational complexity of the method. Balansed parameters most preferred to segmentation method to reduce performance degradation. The modified Ant Colony Optimization (ACO) – k-means and optimal heuristic parameters investigation for complexly structured images are considered in this paper.

Keywords: *Complexly structured images segmentation, Ant colony optimization, k-means algorithm, swarm intelligence.*

1. Introduction

Areas of demand for digital image recognition include medical, aerospace, industry and art. [1]. Complexly structured images belong to the most complex and important objects. Complexly structure images are images with non-deterministic and nonlinear structures composed of many complex elements with important properties. Such images are semantically rich images. A complexly structured image have the following properties:

• Presence of many different objects on the image;
• The objects in the images are of different types;
• Each type of object has unique characteristics that must be considered;
• Objects are morphologically complex entities;
• Object and background color distributions rarely overlap.

Examples of such images include geographic and topographical maps and images of the Earth's surface from space. The most obvious example of images with complex structures are those acquired using medical imaging, especially magnetic resonance imaging (MRI imaging).

Segmentation is the process of dividing a source image of size M×N into K clusters that are as different from each other as possible and represent objects in the source image. Cluster is a specific isolated region composed of distinct elements (pixels) such that the distance between elements is minimal and the distance between two adjacent regions is maximal.

Ant methods have shown competitiveness in solving many NP-complete transcomputation problems [2] and have been noted for use in image segmentation problems [3, 4].

It has the following input parameters:

• K – the number of clusters that input image need be split to;
• m – the number of ants that perform segmentation;
• n_{t0} – the maximum number of iterations for the algorithm;
• α – heuristic parameter that controls the degree of influence on pheromone levels;
• β – heuristic parameter that controls the degree of belonging of a pixel to a certain cluster.

In this article we will investigate heuristic parameters α and β of proposed algorithm.

2. Hybrid Ant colony optimization k-means method for image segmentation

Distinguishing features of the proposed bio-inspired ant image segmentation method are the use of fast cluster analysis (k-means) [6] to recompute the center of each segment and the use of overlays for some criteria. A solution obtained by considering both the color and geometric properties of the image [7–11]. The images are either color or grayscale and have different initial conditions (noise, high contrast, high quality, blur).

In the first step of the procedure, we need to set the value of the number of clusters and initialize their centers. Furthermore, the membership of each pixel of an image in a particular cluster is determined according to a probability that is inversely proportional to the distance between the pixel, the center of the cluster, and the variable τ representing the pheromone level:

$$P_i(X_n) = \frac{\left[\tau_i(X_n)\right]^{\alpha}\left[\eta_i(X_n)\right]^{\beta}}{\Sigma_{j=0}^{K}\left[\tau_j(X_n)\right]^{\alpha}\left[\eta_j(X_n)\right]^{\beta}}, \quad (1)$$

where $\tau_i(X_n)$ and $\eta_i(X_n)$ – pheromone and heuristic variable values of belonging of a pixel to the cluster i respectively, α and β – heuristic coefficients, k – number of clusters. Heuristic information can be calculated as follows:

$$\eta_i(X_n) = \frac{k}{CDist(X_n, CC_i) * PDist(X_n, PC_i)}, \quad (2)$$

where X_n nth pixel, CC_i – i^{th} spectral cluster center, PC_i – i^{th} spatial cluster center, $CDist(X_n, CC_i)$ – distance between (X_n, CC_i) according to color characteristics – (3), $PDist(X_n, PC_i)$ – the geometrical distance between (X_n, PC_i) – (4), k – constant value.

$$CDist(X_n, CC_i) = \left|Int(X_n) - Int(CC_i)\right|, \quad (3)$$

where $Int(X_n)$ is the intensity of the pixel X_n.

$$PDist(X_n, PC_i) = \sqrt{(X_n.x - PC_i.x)^2 + (X_n.y - PC_i.y)^2}, \quad (4)$$

where $X_n.x$ and $X_n.y$ are x and y coordinates respectively for the pixel X_n.

The target function is important for bio-inspired ant method. In the bio-inspired ant method proposed in this article to solve the problem of segmentation

of a complexly structured image, the following set of rules will serve as criteria for finding the optimal solution:

- $\max_{i=1..m} \left(\sum_{k=1..K-1} \sum_{j=k+1..K} CDist(C_k, C_j) \right)$ – Maximum cumulative color distance between cluster centers for all ants (inter-cluster distances for color features must be maximal and clusters are distinct from each other), where CDist – the color distance between two pixels, C_k – center of the cluster *k*.

- $\min_{i=1..m} \left(\sum_{k=1..K} \sum_{p=1..S_k} PDist(C_k, X_p) \right)$ – The minimum sum of geometric distances between the center of a cluster and the pixels belonging to the cluster (the sum of Euclidean distances between the center of a cluster and each of its pixels should be minimized according to spatial properties, respectively , the clusters are more uniform), where S_k – the number of pixels in cluster *k*, PDist – Euclidian distance between two pixels, C_k – center of the cluster *k*.

- $\min_{i=1..m} \left(\sum_{k=1..K} \sum_{p=1..S_k} CDist(C_k, X_p) \right)$ – the minimum sum of color distances between the center of a cluster and the pixels belonging to the cluster (the sum of the Euclidean distances between the center of a cluster and each pixel should be minimal depending on the color characteristics. It will be more compact), where S_k – the number of pixels in the cluster *k*, *CDist* – the color distance between two pixels, C_k – center of the cluster *k*.

The fitness function of the ant colony is 3-criterial and can be obtained as follows:

$$f(m_i) = \begin{cases} f_1 = \sum_{k=1..K-1} \sum_{j=k+1..K} CDist(C_{m_i k}, C_{m_i j}) \\ f_2 = \sum_{k=1..K} \sum_{p=1..S_{m_i k}} PDist(C_{m_i k}, X_{m_i p}) \\ f_3 = \sum_{k=1..K} \sum_{p=1..S_{m_i k}} CDist(C_{m_i k}, X_{m_i p}) \end{cases} \quad (5)$$

Choice of the best solution can be presented as:

$$f(best) = \sum_{i=1..m} \begin{cases} \max(f_1) \\ \min(f_2) \\ \min(f_3) \end{cases} \quad (6)$$

Pheromone updating is calculated as in standard ACO algorithm according to:

$$\tau_i(X_n) \leftarrow (1-\rho)\tau_i(X_n) + \sum_i \Delta\tau_i(X_n) \quad (7)$$

and pheromone evaporation is calculated as:

$$\Delta\tau_i(X_n) = \begin{cases} \dfrac{Q*Min(k')}{AvgCDist(k',i)*AvgPDist(k',i)}, & if\ X_n \subset cluster\ i \\ 0, & otherwise \end{cases} \quad (8)$$

where Q is a constant value, $Min(k')$ – the minimum color outer cluster distance found by the most successful ant, $AvgCDist(k',i)$ and $AvgPDist(k',i)$ – the average value of the spatial Euclidean and color distances between each pixel and cluster centers for the most successful ant.

Modified ACO algorithm for image segmentation contains the next steps:

Algorithm 1. Modified ACO-k-means segmentation algorithm

```
Begin
  Initial set([number of clusters], [number of ants]);
  Repeat
  For each ant do
    M: For each pixel of image do
      Calculate(probability of belonging pixel to cluster) (1);
    End
    Update (cluster current center);
    If (NewCenter <> OldCenter) then
       goto M;
    Else
       Save(current solution);
  End
  Select Best Solution From All Ants (5);
  Update(for each pixel) (6, 7);
  Correct(common solution);
  Until criteria not reached
End
```

3. Determination of the heuristic parameters for the modified ant method

To determine the optimal values of the parameters, we will conduct experimental studies for the developed hybrid ant method of segmentation. We will explore the parameters α – the degree of influence of the pheromone and β – the degree of belonging of a pixel to a certain cluster. To test the segmentation method, we use a set of well-known complexly structured images from Ossirix [5] set.

The original images were divided into several groups. Here, we describe general research methods for determining the optimal parameters of the hybrid Ant method. Using as an example a complex snapshot from his BRAIN collection of the Ossirix set named IM-0001-0002.dcm. This complex structure image has the following parameters: Width – 109; Height – 106; Good Quality; Format – 8 bits per pixel. Size – 38KB; Group is Brain. The cluster parameter is the number of clusters $K = 5$. Maximum number of method iterations. To identify the optimal values for the parameters of the hybrid ant segmentation method, we examined images with different initial conditions (noise, contrast, blur).

To model segmentation taking into account the correction of heuristic coefficients, for several ants from the current population, the heuristic parameters α and β, obtained earlier by the best solution f(best) for a given number of ants, were used. The corresponding results in the form of the dependence of the number of iterations on the number of agents before and after the introduction of individuals with coefficients from the best solutions are presented on fig. 1.

Fig.1. Number of iterations before and after coefficient correction α and β

As can be seen from the results, the correction of α and β in the general case leads to a decrease in the number of iterations of the method and the overall running time.

Final investigation table for MRI images of various initial conditions (noise, contrast, blur) presented below.

Table 1

Optimal α and β values for different types of MRI images with various initial conditions

Type		Group		
		Brain	**Heart**	**Lungs**
Noisless	α	0,121 ± 0.0001	0,197 ± 0.025	0,205 ± 0.015
	β	0,52 ± 0.035	0,427 ± 0.051	0,457 ± 0.07
Contrast	α	0,217 ± 0.022	0,169 ± 0.071	0,17 ± 0.028
	β	0,71 ± 0.044	0,331 ± 0.021	0,357 ± 0.012
Blur	α	0,321 ± 0.002	0,368 ± 0.025	0,271 ± 0.035
	β	0,61 ± 0.021	0,23 ± 0.017	0,257 ± 0.028
Good quality	α	0,14 ± 0.017	0,121 ± 0.053	0,312 ± 0.023
	β	0,437 ± 0.032	0,502 ± 0.025	0,437 ± 0.034

4. Conclusion

In the article was presented Hybrid ACO-k-means method for complexly structured images segmentation. Optimal heuristical parameters α and β were investigated and proposed recommended values for usage.

5. Acknowledgements

The reported study was funded by a grant from the Russian Science Foundation according to the research project № 23-21-00089.

References

1. Gonzalez R.C., Woods R.E., Digital Image Processing, 3rd edition, Prentice-Hall, 2008.
2. Kennedy J, Eberhart R.C. Particle swarm intelligence // In Proceedings of the IEEE International Joint Conference on Neural Networks. – 1995. – P. 1942–1948.
3. Bozhenyuk A., El-Khatib S., Kacprzyk J., Knyazeva M., Rodzin S. (2019) Hybrid Ant Fuzzy Algorithm for MRI Images Segmentation. // In: Rutkowski L., Scherer R., Korytkowski M., Pedrycz W., Tadeusiewicz R., Zurada J. (eds) Artificial Intelligence and Soft Computing. ICAISC 2019. Lecture Notes in Computer Science. – Vol 11509. – Springer, Cham. Doi: https://doi.org/10.1007/978-3-030-20915-5_12

4. Saatchi, S. and C.C. Hung, 2007. Swarm intelligence and image segmentation swarm intelligence. ARS J.

5. Ossirix image dataset. http://www.osirix-viewer.com/

6. Hartigan J. A., Wond M.A. Algorithm AS 136: A K-Means Clustering Algorithm // Journal of the Royal Statistical Society. – Series C28(1). – 1979 – P. 100–108.

7. Skobtsov YA, Speransky DV Evolutionary computation: hand book.-Moscow: The National Open University "INTUIT" 2015. – 331p. (in Russian).

8. El-Khatib S., Skobtsov Y., Rodzin S. (2020) Improved Particle Swarm Medical Image Segmentation Algorithm for Decision Making. In: Kotenko I., Badica C., Desnitsky V., El Baz D., Ivanovic M. (eds) Intelligent Distributed Computing XIII. IDC 2019. Studies in Computational Intelligence, vol 868. Springer, Cham

9. El-Khatib, S. A., Skobtsov, Y. A. and Rodzin, S. I. (2019) 'Theoretical and Experimental Evaluation of Hybrid ACO-k-means Image Segmentation Algorithm for MRI Images Using Drift-analysis', *Procedia Computer Science*, 150. – P. 324.

10. El-Khatib S., Skobtsov Y., Rodzin S., Zakharov V. (2021) Comparison of Modified Object Detected Graph Cut and Hybrid Ant Colony Optimization - k-means for MRI Images Segmentation. In: Silhavy R. (eds) Software Engineering and Algorithms. CSOC 2021. Lecture Notes in Networks and Systems, vol 230. Springer, Cham. https://doi.org/10.1007/978-3-030-77442-4_58

11. El-Khatib S., Skobtsov Y., Rodzin S., Zakharov V. (2022) Optimal Number of Ants Determination for Ant Colony Optimization Image Segmentation Method for Complexly Structured Images In: Silhavy R. (eds) Artificial Intelligence Trends in Systems. CSOC 2022. Lecture Notes in Networks and Systems, vol 502. Springer, Cham. https://doi.org/10.1007/978-3-031-09076-9_52

М.В. МАКАРОВ, И.А. СЕМЕНОВ, Н.С. ПИДЖАКОВА

Муромский институт Владимирского государственного университета
им. Александра Григорьевича и Николая Григорьевича Столетовых
nauka-murom@yandex.ru

СИСТЕМА ЛОГИЧЕСКОГО ВЫВОДА ДЛЯ НОВОГО ТИПА ЭВРИСТИЧЕСКИХ РЕШЕНИЙ В РАМКАХ АДАПТИВНОГО УПРАВЛЕНИЯ МОБИЛЬНЫМ РОБОТОМ*

В статье представлены теоретические сведения, раскрывающие принципы осуществления логического вывода эвристических решений нового

* Исследование выполнено за счет гранта Российского научного фонда № 22-21-20111, https://rscf.ru/project/22-21-20111/

типа, синтезируемых внутри системы управления мобильного робота. Проведено экспериментальное исследование, направленное на обоснование эффективности предлагаемого подхода для решения обозначенной задачи. Выявлено, что подобный вариант реализации данной процедуры способствует повышению адаптационных способностей робота при его автономном функционировании в условиях динамической среды.

Ключевые слова: *мобильные роботы, логический вывод, адаптивное управление, принятие решения.*

Введение

Для автономного управления мобильным роботом (МР) в динамической среде существования требуется адаптация поведенческих функций к внешним условиям. Для этой цели с высокой степенью эффективности могут применяться принципы понятийного или абстрактного мышления внутри технической системы [1–2]. Подобный подход к обработке информации и принятию решения обладает нечеткой природой и его применение невозможно без строгой формализации решения и передачи варианта его математического представления в исполнительно-двигательные органы МР для выполнения различных прикладных задач в рамках своих компетенций. Поэтому необходимым условием воплощения в жизнь подобной интеграции искусственного интеллекта в МР является формирование системы логического вывода, позволяющего получать вектор однозначно интерпретируемых количественных значений параметров управления, что будет способствовать реализации поведенческих функций.

Теоретические аспекты исследования

Данная работа основывается на теоретической концепции синтеза эвристических решений нового типа, отдельные элементы которой были раскрыты ранее в статьях [3–4]. В рамках этой концепции используются особые принципы обработки информации, следовательно, для её полной реализации необходима организация релевантного логического вывода.

Описание особенностей предлагаемых механизмов обработки информации следует начать с рассмотрения процесса адаптивного управления МР. Если попытаться определить существующее представление об адаптивном управлении интеллектуальными техническими системами в целом и МР в частности, то его можно представить как автономную коррекцию параметров модели решений при изменении текущих условий внешней среды [5–7]. Однако параметрическая или даже структурная пластичность

такой системы не является исчерпывающим инструментом для обеспечения инвариантности МР к условиям среды существования. Дополнительные возможности могут возникнуть, если соотносить процесс функционирования МР с феноменом поведения, которое можно охарактеризовать как рациональное использование ресурсов системы для реакции на импульсы, побуждающие её к осуществлению физических исполнительно-двигательных активностей в рамках своих компетенций. В большинстве случаев эти активности связаны с перемещением МР в оперативном пространстве или реализации иных механических действий исполнительными органами его сочленений. В случае обращения к рациональности действий неизбежным будет наличие квази-когнитивных свойств в системе, то есть способности внесения смысла (стратегическое или тактическое планирование и оценка последствий решений) в свои действия.

Согласно используемой концепции, внесение смысла в процессы обработкой информации означает, что важен не столько количественный результат, который мы получили в ходе преобразования данных, сколько представление о том, как мы его получили. В таком случае появляется новый информационный поток способный описывать различные объекты, явления и процессы на качественном уровне. Средством обобщения элементов описанного выше типа решения, формирующей его целостность, является сетевая вычислительная структура, которая формирует требующуюся информационную двойственность, а её элементы можно представить как особый вид нейронов, существующих в псевдо-физической логике с внутренним дополнительным измерением, позволяющим выстраивать функциональные зависимости от единой величины. Реализация этого возможна с помощью математического аппарата вариационных исчислений.

Методология исследования

Методология проведенного экспериментального исследования была направлена на обоснование реализуемости предлагаемых программных процедур, формирующих систему логического вывода, а также на оценку эффективности предлагаемых механизмов обработки информации для синтеза решения эвристических решений нового типа в рамках становления адаптационных способностей МР при его функционировании в условиях динамической среды существования.

Для описания качества работы системы логического вывода каждое синтезируемое системой решение было оценено по следующим критериям: возможность интерпретируемости результата и однозначность интерпретируемости результата. Это должно было позволить обосновать эффективность предлагаемого подхода для решения поставленной задачи.

В качестве объекта исследования использовалась компьютерная модель абстрактного разведывательного МР. С целью её создания была задействована виртуальная среда моделирования роботов Robot Operating System (ROS) в сочетании с динамическим 3D симулятором с открытым исходным кодом Gazebo и языком программирования Python. Предусмотрено воссоздание виртуальных сред существования модели за счёт использования находящихся в открытом доступе готовых ROS-моделей замкнутых пространств внутри различных помещений. Сбор сенсорной информации для осуществления реалистичного поведения модели при взаимодействии со статическими и динамическими компонентами внешней среды выполнялся средствами лидарного сканирования и визуальной одометрии.

Проведен ряд экспериментов внутри 20 различных по конфигурации виртуальных пространств, где в каждом случае симулировалось перемещение модели МР в директивно задаваемую точку. Предусмотрено, что в первую очередь будет осуществлен сбор информации о поведении объекта исследования при решении задачи навигации одним из существующих алгоритмических методов с элементами интеллектуальной обработки информации. Для этого использовался наиболее эффективный алгоритм исполнения процедуры локализации и картографирования TinySLAM с интеллектуальным построением динамической сетки занятости DOG, как это было выполнено в работе [8]. В результате получено 20 траекторий, в которых для сравнительного анализа использовались по 200 шагов. Анализ состоял в оценивании каждого принятого решения о дальнейшем шаге модели МР. Это стало возможно благодаря переходу к бинарной классификации принятых решений: верно принятое решение, то есть способствующее получению оптимальной с точки зрения затрачиваемого времени на перемещение траектории при учёте ограничений, накладываемых динамическими и статическими объектами, а также неверно принятое решение, которое вызывает обратный эффект. Количественная оценка верности или неверности принятых решений в контексте затрачиваемого времени на перемещение модели МР осуществлялась с помощью рекурсивных методов динамического программирования.

Затем в систему были инкорпорированы предлагаемые механизмы обработки информации и принятия решения с последующим прохождением аналогичных маршрутов. Вследствие этого появилась возможность сравнить полученные траектории и оценить изменения принимаемых решений объектом исследования, а также как эти изменения повлияли на время достижения цели.

Кроме того, эксперименты повторялись в различных условиях, характеризующихся уровнем динамических свойств оперативного пространства

объекта исследования. Следовательно, можно выделить несколько этапов, на первом из которых модель функционировала без взаимодействия с динамическими объектами, а далее в рамках используемых оперативных пространств последовательно осуществлялось добавление четырех типов динамических дестабилизирующих воздействий: появляющихся и исчезающих объектов, равномерно движущихся объектов, движущихся объектов с ускорением, искривляющих пространство объектов.

Результаты исследования и их обсуждение

В ходе проведения экспериментального исследования симулировалась работа разработанной компьютерной модели МР, в ходе которой на вход системы управления подавались результаты исполнения процедуры локализации и картографирования (динамическая сетка занятости). На основе этого формировалось суждение, указывающее на одну из возможных активностей для текущего шага: движение вперед согласно принятой траектории, поворот вправо, поворот влево, отклонение от траектории принятой вправо, отклонение от принятой траектории влево, остановка и ожидание или разворот.

Для этого была использована особая структура данных, которая может быть представлена в виде тензора, распределенного в глубину и строящегося в этом направлении из уровней. Верхним уровнем является проекция динамической сетки занятости оперативного пространства. Последующие в глубину уровни отображают в системе доступные ресурсы. Для демонстрации результатов выполнения процедуры логического вывода произведена количественная оценка эффективности инкорпорации предлагаемых механизмов в состав системы управления. Вся статистика, отражающая качество работы системы логического вывода представлена в табл. 1.

Ещё одним критерием, показывающим важность полученных результатов, является установление факта отсутствия полной зависимости принимаемых решений от вектора входной информации. Усовершенствованная система управления меняла решения при аналогичных сенсорных воздействиях, что указывает на формирование внутреннего субстрата необходимого для дополнительной оценки текущей ситуации исходя из воздействия динамических дестабилизирующих факторов.

Согласно реализуемой методологии по всем проведенным экспериментам собирались статистические данные, представляющие собой сравнительные характеристики принимаемых решений исходной модели МР и усовершенствованной. В результате получена представленная на рис. 1

ROC-диаграмма, показывающая отношение доли верно измененных решений от их общего числа (True Positive Rate) к неверно измененным решениям от их общего числа (False Positive Rate).

Таблица 1

Статистика по качеству работы системы логического вывода

№ эксперимента	1	2	3	4	5
Доля ситуаций без возможности однозначной интерпретации решения от общего числа	0.01	0.015	0.035	0.025	0.01
Доля ситуаций без возможности интерпретации решения от общего числа	0.01	0.015	0.025	0.005	0.015
№ эксперимента	6	7	8	9	10
Доля ситуаций без возможности однозначной интерпретации решения от общего числа	0.01	0.015	0.01	0.005	0.015
Доля ситуаций без возможности интерпретации решения от общего числа	0.015	0.045	0.005	0.035	0.04
№ эксперимента	11	12	13	14	15
Доля ситуаций без возможности однозначной интерпретации решения от общего числа	0.045	0.005	0.035	0.005	0.005
Доля ситуаций без возможности интерпретации решения от общего числа	0.025	0.03	0.015	0.035	0.005
№ эксперимента	16	17	18	19	20
Доля ситуаций без возможности однозначной интерпретации решения от общего числа	0.015	0.010	0.01	0.005	0.04
Доля ситуаций без возможности интерпретации решения от общего числа	0.015	0.045	0.05	0.045	0.04

Из ROC-диаграммы можно увидеть, что при различных по дестабилизирующему воздействию четырех уровнях динамических свойств оперативного пространства объекта исследования присутствовала существенная доля верных изменений решений вызванных инкорпорацией механизмов синтеза эвристических решений нового типа. Можно констатировать, что на всех уровнях удалось добиться результатов, позволяющих говорить о

существенном повышении адаптационных способностей модели МР. Данный процесс стабилен и не обладает аномалиями, а также стационарен для всех 20 помещений, в которых осуществлялись эксперименты.

Рис. 1. Сравнительный анализ принимаемых решений при исходной модели процесса обработки информации и усовершенствованной в контексте влияния этих решений на качество функционирования МР

Выводы

Полученные результаты позволяют сделать вывод, что существует возможность формирования механизмов обработки информации, которые могли бы использоваться в качестве субстрата для синтеза нового типа эвристических решений внутри системы управления МР в динамической среде существования. В рассматриваемых случаях внесение структурных изменений в компонент принятия решения привело к возникновению отклика в адаптационных способностях объекта исследования при дестабилизации внешних условий. Важным элементом этого процесса является особый логический вывод, который может быть эффективно реализован с помощью средств двойственного представления информации и способствует расширению поведенческого потенциала МР.

Список литературы

1. Мелехин В.Б., Хачумов М.В. Виды мышления автономных интеллектуальных мобильных систем и особенности их организации // Материалы 15-й мультиконференции по проблемам управления. 2022. С. 47–50.
2. Мелехин В.Б., Хачумов М.В. Принцип конкретизации абстрактных знаний автономным интеллектуальным роботом в процессе планирования поведения в условиях неопределенности // Морские интеллектуальные технологии. 2023. № 1. Ч. 1. С. 181–190.
3. Makarov M., Astafiev A. Researching the Fundamentals of Decision Synthesis into Technical Systems of Intelligent Data Processing // Lecture Notes in Electrical Engineering. 2022. V. 857. P. 414–423.
4. Макаров М.В., Семенов И.А., Демидов А.А., Трантина Н.С. Исследование нового типа эвристических решений для адаптивного управления мобильным роботом в динамической среде // Нейроинформатика-2022. XXIV Международная научно-техническая конференция. Сборник научных трудов. М.: МФТИ. 2022. С. 174–183.
5. Ермолов И.Л., Хрипунов С.П. Возможный подход к созданию самообучающихся систем управления автономными роботами // Робототехника и техническая кибернетика. 2023. Т. 11. № 1. С. 45–50.
6. Шмалько Е.Ю., Серебренный В.В. Применение методов машинного обучения для расчета синтезированного оптимального управления мобильным роботом // Экстремальная робототехника. 2022. Т. 1. № 1. С. 340–347.
7. Степанов М.Ф., Степанов А.М., Степанова О.М. Аспекты самоорганизации и алгоритм решения задач интеллектуальных систем группового управления // Экстремальная робототехника. 2022. Т. 1. № 1. С. 362–371.
8. Макаров М.В., Астафьев А.В., Семенов И.А. Исследование интеллектуальных элементов управления мобильным роботом и обеспечение информационной безопасности процесса его функционирования в динамической среде // Известия Юго-Западного государственного университета. 2022. № 2(26). С. 72–86.

К.А. ФЕДОРОВ, М.Ю. НАЗАРЬКО, А.В. САМСОНОВИЧ
Национальный исследовательский ядерный университет «МИФИ»
avsamsonovich@mephi.ru

УПРАВЛЕНИЕ ОБУЧЕНИЕМ НЕЙРОННЫХ СЕТЕЙ С ПОМОЩЬЮ ГЕНЕТИЧЕСКОГО АЛГОРИТМА

Рассматривается задача интеграции работы генетического алгоритма и глубокого обучения нейронных сетей. Разработан подход, основанный на модификации с помощью генетического алгоритма не параметров нейросетей, а наборов данных, используемых для обучения нейросетей. Сами

наборы данных отображают историю поведения агента в окружении и выступают в роли генотипа. Фенотипом является обученная нейросеть. При этом архитектура и гиперпараметры нейросети и модели ее обучения остаются фиксированными. Результаты численных экспериментов на примере игры «Три ковбоя» подтверждают работоспособность данного метода обучения.

Ключевые слова: *генетический алгоритм, глубокое обучение, интеграция.*

Введение

Задача интеграции методов глубокого обучения и генетических алгоритмов (ГА) – найти такое их объединение, при котором сильные стороны обоих методов соединяются, а слабые компенсируются. До сих пор применение ГА к обучению нейросетей или других статистических моделей ограничивалось главным образом модификацией посредством ГА параметров и архитектуры модели [1, 2] или же гиперпараметров процесса ее обучения [3]. Альтернативный пример подхода к интеграции – использование глубокой нейросети для реализации функции фитности ГА [4].

В настоящей работе рассматривается идея о том, что более продуктивным может оказаться подход, при котором ГА напрямую не воздействует ни на саму нейросеть, ни на процесс ее обучения. Вместо этого, ГА используется для модификации наборов данных, на которых обучается нейросеть. Модификация осуществляется посредством рекомбинаций и мутаций, применяемых напрямую к самим данным, а не к их параметрам или к вероятностям выбора тех или иных данных для обучения. В этом смысле наборы данных выступают в роли генотипа.

Общая постановка задачи и подход к решению

Рассмотрим поведение агента, состоящее из последовательности дискретных действий в некотором окружении в рамках некоторой парадигмы: например, игры с определенной целевой функцией. Пусть действиями агента управляет нейросеть, получающая на вход состояние окружения и выдающая на выходе конкретный выбор действия. Нейросеть обучается на примерах поведения, а процессом ее обучения управляет ГА.

По завершении каждого матча игры агент получает оценку своей целевой функции, определяемую как его действиями, так и событиями в окружении: например, действиями соперников или партнеров. Задача обучения

нейросети, а также ГА, управляющего процессом обучения – достичь как можно большего среднего значения целевой функции в рамках данной поведенческой парадигмы.

Согласно предложенному подходу, ГА не будет напрямую влиять на архитектуру или параметры нейронной сети. Вместо этого, в процессе игры будут собираться данные о поведении особей-агентов. Собранные данные будут подвержены отбору и модификации путем рекомбинаций, после чего они будут использоваться как наборы данных для обучения следующего поколения. При этом будет использоваться обучение с учителем.

Такой подход к объединению работы ГА и обучения нейронных сетей является универсальным, поскольку позволяет использовать любую архитектуру нейронной сети. Архитектура может также меняться в процессе эволюции. Главное, чтобы нейросеть могла обучаться на собранных данных о поведении агента. Данный метод может использоваться для любой парадигмы, в которой присутствует агент, каким-либо образом взаимодействующий с окружением, и имеется целевая функция – оценка поведения агента.

Процедура скрещивания наборов данных может быть любой при условии, что она не нарушает целостность эпизодов поведения, таких как матчи игры. Скрещивания, например, могут переставлять эпизоды поведения разных игроков.

Роль мутации в данном случае играет использование для обучения новой особи набора данных, состоящего исключительно из эпизодов поведения одного из родителей. Мутация в таком виде не сводится к копированию, так как при обучении на одинаковых наборах данных внутренние весовые коэффициенты нейронных сетей могут получаться различными: будет иметь место изменчивость.

Мы ограничимся рассмотрением случая, когда набор данных представляет собой временной ряд. Архитектура нейронной сети, часто используемая для обработки данных такого типа – это LSTM. Причина в том, что LSTM слой способен обучаться воспроизведению долгосрочных зависимостей во временных рядах [5].

Конкретная постановка задачи и ее формализация

Для проверки работоспособности концепции предлагаемого подхода, в качестве экспериментальной парадигмы в данной работе была выбрана игра «Три ковбоя». В данной игре участвуют три соперника – «ковбоя», причем матч состоит из серии раундов: поединков между ковбоями. Цель игры – набрать максимальное количество очков в матче.

Условия игры таковы. Каждый ковбой имеет один однозарядный пистолет, который не может быть передан другому ковбою. Все трое находятся в открытом ограниченном пространстве, постоянно видят все действия друг друга, включая прицеливание, и являются отменными стрелками (стреляя в цель, не промахиваются). В каждом раунде стрельба начинается после сигнала и прекращается по истечении отведенного интервала времени. В конце раунда тот, в кого не попал выстрел, получает 10 очков плюс еще одно очко, если он сам в кого-то попал. Тот, в кого попали, не получает ничего.

Очевидно, что при данных условиях ковбои должны соперничать друг с другом, однако их оптимальное поведение – произвести выстрел в воздух. Данный результат – самый гуманный с человеческой точки зрения. Эту версию игры можно назвать миролюбивой. В другом, агрессивном варианте игры, вводится дополнительное условие: если в конце раунда ни в кого не попали, то проигрывают все.

Выбранный пример экспериментальной парадигмы имеет несколько особенностей. Во-первых, нет заранее подготовленных данных, с помощью которых можно было бы предобучить нейронную сеть. Во-вторых, нет абсолютного критерия оценки качества ковбоя: об оптимальности полученного индивидуума можно судить как по его способности побеждать в той популяции, где он развивался (локальная приспособленность), так и в произвольной, заранее неизвестной ему популяции ковбоев (абсолютная приспособленность). Это различие существенно, так как популяция в процессе эволюции может сформировать внутренний язык, например на основе сигнализации через определенную последовательность прицеливаний, которую будут понимать только представители данной конкретной популяции.

Используя более формальный язык, задачу можно описать следующим образом.

- Под ковбоем понимается агент, способный совершить действия, указанные ниже:
  - бездействие — обозначим как DN;
  - прицеливание в конкретного (одного из двух) соперника – обозначим как AM_i, где i — номер противника, на которого направлен пистолет;
  - выстрел в конкретного (одного из двух) соперника – обозначим как ST_i, где номер i определяется аналогично предыдущему случаю;
  - выстрел в воздух — обозначим как SA;
  - «выжил» — AL;
  - «мертв» — DE.

- Ковбой может совершать действия не чаще чем раз в несколько тактов (тиков дискретного времени). Эта характеристика агента называется временем реакции. Она меняется случайным образом после совершения каждого действия, оставаясь в заданном диапазоне, и неизвестна заранее.
- Множество возможных состояний ковбоев будем обозначать как $states = \{DN, AM_i, ST_i, SA, DE, AL, DE\}$.
- Введем функцию оценки ковбоя в раунде:

$$f(x) = m, x \in states, m \in Z \ , \quad (1)$$

определив ее следующим образом.
  - Если ковбой умер, оценка за раунд равна нулю $f(DE) = 0$;
  - Если ковбой выжил, то оценка за раунд равна десяти $f(AL) = 10$;
  - Если ковбой выжил и убил ковбоя, то оценка за раунд составляет одиннадцать $f(ST_i) = 11, i \in 0 \dots (K-1)$;
  - Во втором варианте игры также есть правило, при котором вся группа, участвующая в матче, получает 0 очков в случае, если в течение матча никто не погиб.
- Под раундом понимается единственный поединок трех ковбоев. В поединке каждому агенту присваивается количество очков (баллов) согласно функции (1) оценки ковбоев в раунде.
- Под матчем понимается последовательная серия раундов одной группы ковбоев.
- Введем функцию определения победителя в матче:
  - Победитель в матче – ковбой с максимальной суммой баллов за серию раундов:

$$WN = argmax_{x=1\dots K}(\sum_1^N f(M_{x,i})), \quad (2)$$

где $M_{x,i}$ — статус ковбоя с именем x на i-ом шаге раунда.
- Поведение агента может зависеть от разных параметров, к которым можно отнести:
  - текущие статусы соперников (значения из множества states);
  - предыдущие статусы соперников (значения из множества $states$);
  - статусы соперников, которые они имели в предыдущих раундах матча (значения из множества $states$).

Из предыдущего пункта можно сделать вывод, что для принятия решения ковбою необходимо учитывать все статусы, которые имел каждый из

ковбоев-противников на протяжении всего матча – в общем случае последовательность статусов ковбоев представляет временной ряд. Данное обстоятельство не позволяет использовать способы скрещивания и мутации, нарушающие логическую связь между событиями.

Результаты численных экспериментов и их анализ

В ходе работы были проведены численные эксперименты в рамках описанной парадигмы игры «Три ковбоя». Были протестированы оба варианта игры: миролюбивый и агрессивный. Были протестированы запуски с критерием остановки и без, а также различные конфигурации, определяемые значениями гиперпараметров. Полученные результаты таковы.

В миролюбивом варианте выяснилось, что агенты достаточно быстро приходят к миролюбивому поведению в случае, если их окно реакции не варьируется (рис. 1).

Рис. 1. Пример эволюции популяции в миролюбивом варианте игры

На рис. 1 и 2 изображены следующие данные:

- по оси x отложен номер поколения популяции;
- по оси y отмечается количество очков, набранных в отборочных матчах;

- синяя линия – минимальное количество очков в популяции;
- оранжевая линия – среднее количество очков в популяции;
- зеленая линия – максимальное количество очков, набранное в популяции.

Запуск системы в случае рис. 1 производился при следующих значениях гиперпараметров: время реакции фиксировано и составляет 1 тик, размер популяции – 99, количество отобранных особей – 60, количество перемешиваний групп – 20, количество матчей в рамках группы – 5. Как видно на примере эволюции, показанном на рис. 1, изначально агенты стреляли друг по другу, однако после их агрессивность снижается, и на восьмом поколении они приходят к миролюбивой стратегии поведения, которая позволяет всем безопасно набрать существенное количество очков.

После этого было исследовано поведение системы в агрессивном варианте игры. Результаты представлены на рис. 2.

Рис. 2. Пример эволюции популяции в агрессивном варианте игры

Запуск системы в случае рис. 2 производился при следующих значениях гиперпараметров: время реакции фиксировано и составляет 1 тик, размер популяции – 30, количество отобранных особей – 12, количество перемешиваний групп – 4, количество матчей в рамках группы – 6. Как видно из рис. 2, агенты достаточно быстро приходят к стационарной ситуации, если говорить об их способности побеждать друг друга. Это также проявляется

и в том, что после небольшого количества поколений система сразу проходит критерий остановки алгоритма, определенный изначально как набранные 90 % от максимально возможного количества очков лучшим индивидуумом. Поэтому критерий остановки был изменен, как описано ниже.

Поскольку даже при большом количестве сыгранных матчей среднее количество очков, набранных в процессе отбора, оставалось примерно на одном уровне, было принято решение разработать критерий остановки, предполагающий проведение контрольных матчей с «эталонным» агентом, поведение которого контролирует заранее написанный алгоритм. В таком критерии остановки важно количество матчей, которое не выиграл агент, управляемый алгоритмом против двух агентов из популяции. Долю матчей, которую необходимо выиграть, также можно регулировать. Также на этом этапе эволюция запускалась с одинаковыми настройками многократно для набора статистики. Результаты представлены на рис. 3.

Рис. 3. Статистика контрольных матчей
как функция номера поколения в агрессивном варианте игры

Конкретно на рис. 3 изображены следующие данные:

- по оси x отложен номер поколения популяции;
- по оси y отложено количество очков, набранное в тестовых матчах с «эталонными» агентами;
- синяя линия – количество очков, набранное в тестовых матчах первым агентом из популяции;

- оранжевая линия – количество очков, набранное в тестовых матчах вторым агентом из популяции;
- зеленая линия – количество очков, набранное в тестовых матчах вторым «эталонным» агентом, управляемым заранее написанным алгоритмом;
- границы цветных полос соответствуют доверительным интервалам.

Как видно на рис. 3, сначала агенты из эволюционирующей популяции и их «эталонный» соперник набирали почти одинаковое количество очков, однако потом отобранные эволюционирующие агенты начинают доминировать в каждом матче. К концу эксперимента различие становится весьма значимым в пользу обучившихся нейросетей, что говорит об их развитии.

Рост качества агентов в контрольных матчах наблюдается и тогда, когда количество их очков в отборочных матчах друг с другом остается примерно одинаковым. То есть, относительно друг друга агенты остаются примерно на одном уровне, а относительно фиксированного алгоритма – растут.

Выводы

Предложен и реализован новый метод интеграции глубокого обучения нейронных сетей и ГА. Подход универсален и позволяет работать с различными архитектурами нейронных сетей и решать различные задачи. Численные эксперименты подтверждают работоспособность концепции.

Предложенный подход принципиально отличается от известных подходов к интеграции ГА и моделей обучения нейросетей. В данном случае в роли генотипа, подверженного мутациям и рекомбинациям, выступает набор данных, используемых для обучения нейросети. При этом фенотипом является обученная нейросеть.

Одно из ограничений метода состоит в том, что мутации и рекомбинации не могут нарушать целостность эпизодов поведения: в данном случае, матчей. В дальнейших исследованиях будут предприняты попытки преодолеть это ограничение. Кроме того, необходимо расширить как набор методов скрещивания, так и спектр экспериментальных парадигм. Наконец, необходимо сравнение эффективности данного метода с традиционными аналогами, включая как «чистые» модели ГА и глубокого обучения (прежде всего обучение с подкреплением), так и их гибридные варианты.

Работа финансирована грантом РНФ № 22-11-00213.

Список литературы

1. Levy E., David O.E., Netanyahu N.S. Genetic algorithms and deep learning for automatic painter classification // 16th Genetic and Evolutionary Computation Conference: GECCO 2014. P. 1143–1150. Association for Computing Machinery, Vancouver, BC, 2014. DOI: 10.1145/2576768.2598287.

2. Young S.R., Rose D.C., Karnowski T.P., Lim S.H., Patton R.M. Optimizing deep learning hyper-parameters through an evolutionary algorithm // Workshop on Machine Learning in High-Performance Computing Environments: MLHPC 2015, Article 4. P. 1–5. Association for Computing Machinery, 2015. DOI: 10.1145/2834892.2834896.

3. Erden C. Genetic algorithm-based hyperparameter optimization of deep learning models for PM2.5 time-series prediction // International Journal of Environmental Science and Technology, 2023. V. 20. P 2959–2982. DOI: 10.1007/s13762-023-04763-6.

4. Majidi M., Toroghi R.M. A combination of multi-objective genetic algorithm and deep learning for music harmony generation // Multimedia Tools and Applications, 2023. V. 82 (2). P. 2419–2435. DOI: 10.1007/s11042-022-13329-6.

5. Goodfellow I., Bengio Y., Courville A. // Deep learning. MIT press, 2016.

Секция

Нейроинформатика и искусственный интеллект

В.Е. КУРЬЯН
ООО «АиС», Россия, Москва
kuryan@phystech.edu

АКСИОМЫ ПОСТРОЕНИЯ ГРАФА МОДЕЛИ МИРА

Отмечена принципиальная ограниченность парадигмы «последовательность в последовательность» при построении систем искусственного интеллекта. Описан подход к построению интеллектуальных систем на основе использования модели мира в виде графа, который строится автоматически в процессе обучения. Сформулированы правила (аксиомы) автоматического построения графа модели мира. Показано, что получающаяся модель обладает свойством объяснимости.

Ключевые слова: *дерево модели мира, машинный перевод, аксиомы обучения.*

Введение

Последние годы системы искусственного интеллекта демонстрируют впечатляющие успехи в решении различных задач. Автоматический перевод с одного естественного языка на другой является одной из самых сложных и общих задач для таких систем. Доминирующим подходом в настоящее время является парадигма «последовательность в последовательность», при которой исходный текст рассматривается как упорядоченная последовательность слов (токенов). По этой входной последовательности строится выходная последовательность, которая считается переводом исходного текста. Реализация парадигмы «последовательность в последовательность» при решении задачи автоматического перевода осуществляется различными способами. Среди них стоит отметить использование синтаксического анализа текста и грамматических правил [1], статистический подход [2], использование нейронных сетей для получения перевода [3, 4], метод аналогий [5]. Наибольшего успеха удалось добиться системам на основе моделей языка, среди которых наиболее известна GPT4 [6]. Несмотря на большие успехи и несомненную практическую значимость таких си-

стем, они нередко демонстрируют принципиальную ограниченность используемой парадигмы. В качестве примера можно привести перевод короткого диалога такими системами.

Вот исходный диалог на русском языке:

– Что это?

– Красная смородина.

– А почему белая?

– Потому что зеленая.

Система GPT4 выдала следующий вариант перевода диалога:

– What is it?

– Red currant.

– Why is it white?

– Because it's green.

Формально каждое предложение переведено правильно, но из всего перевода невозможно понять суть. Он не отражает ситуацию в реальном мире, которую описывал исходный диалог. Когда человек читает исходный диалог у него в сознании подбирается соответствующий образ из реального мира, соответствующий тексту диалога, и между текстом и образом устанавливается связь. В системах, реализующих парадигму «последовательность в последовательность» такой связи с реальным миром не образуется. Отсутствие такой связи является принципиальным ограничением этой парадигмы.

Метод, использующий модель мира на основе онтологий описан в [7]. Недостатком этого метода является необходимость ручного построения модели мира. В работах автора [8–12] развит подход к решению задачи перевода с одного естественного языка на другой, использующий модель мира в виде графа. При этом в процессе обучения системы модель мира строится автоматически. Обучение системы (построение модели мира) имитирует обучение человека, а процесс перевода аналогичен тому, как это делает человек. Построенная на таком принципе система будет обладать свойством объяснимости.

Идея автоматического перевода на основе модели мира на естественных языках состоит в том, что одна и та же ситуация во внешнем мире описывается на различных естественных языках. Эти описания называются переводами с одного языка на другой. Перевод выполняется по следующему алгоритму: по входному тексту, описывающему некоторую ситуацию в реальном мире на входном языке, выбирается часть модели мира, соответствующая этому тексту. В качестве перевода на выходной язык выбирается описание этой же части модели мира, но уже на выходном языке. Детально алгоритм перевода описан в предыдущих работах автора [8–12]. В этих работах были

сформулированы простейшие правила (аксиомы обучения) построения модели мира и проиллюстрировано их применение. В данной работе сформулированы более сложные аксиомы обучения, ускоряющие процесс обучения.

Индуктивный подход к построению модели мира

Построение модели мира использует индуктивный подход, при котором выделяются общие закономерности в обучающих текстах и производятся обобщения.

Основная идея автоматического построения модели мира состоит в том, что рассматривается две ситуации во внешнем мире, имеющие нечто общее. Эти ситуации описываются на входном и выходном языках. Общей части этих двух ситуаций во внешнем мире соответствует общая часть в описании на входном и выходном естественных языках соответственно. Эти общие части на входном и выходном языке выделяются и предполагается, что общей части на входном языке соответствует общая часть на выходном языке, различающимся частям ситуаций внешнего мира соответствуют различные части описаний на каждом из языков. При этом можно установить соответствие (перевод) между этими общими и различающимися частями на входном и выходном языках. Выделение общих фрагментов во внешнем мире и их описаний на входном и выходном языках соответствует выделению общих понятий и закономерностей внешнего мира. Далее мы рассматриваем выделенные фрагменты как с самостоятельные ситуации во внешнем мире и их описания на входном и выходном языке. Это соответствует выделению обобщенных понятий и построению иерархической модели.

Считаем, что во входном и выходном языках имеется конечное число слов и словоформ, описание ситуации во внешнем мире представляется упорядоченным набором слов (токенов). Такое описание далее будем называть выражением на входном и выходном языках соответственно. Выражения на входном языке будем обозначать EInum, на выходном EOnum от слова выражение (expression), I (input) входной язык, O (output) выходной язык, num – некоторый числовой или буквенный индекс, нумерующий различные выражения.

Любое выражение может состоять из упорядоченного набора других выражений более низкого уровня иерархии. Выражения удобно представлять в виде графа, в котором каждому выражению соответствует вершина, вершины более низкого уровня соответствуют элементам исходного выражения. Эти вершины соединены ребрами с вершиной исходного выражения.

Построение системой модели мира в виде графа происходит автоматически в процессе обучения. Обучение состоит в подаче системе пар выражений на входном и выходном языках, описывающих одну и ту же ситуацию во внешнем мире. Система сравнивает полученную информацию с уже имеющейся моделью мира и при необходимости производит изменения в текущей модели (в текущем графе) по определенным правилам. Эти правила будем называть аксиомами обучения.

В предыдущей работе [12] были сформулированы две аксиомы обучения. Первая аксиома **A1** гласит, что если выражение EO является переводом EI, то верно и обратное. Вторая аксиома **A2** вводит правило преобразования графа модели мира, которое применяется в том случае, когда выражения на входном и выходном языках могут быть разбиты на две части, одна из которых соответствует общей части описываемой ситуации во внешнем мире, а оставшиеся части соответствуют различиям.

В качестве иллюстрации применения второй аксиомы приведем пример пары выражений на русском и английском языках.

Петя ходит в зоопарк. Петя ходит в кино.

Pit goes to the zoo. Pit goes to the cinema.

В этом примере EI1=Петя ходит в, EI2=зоопарк, EI3=кино, EO1=Pit goes to the, EO2=zoo, EO3=cinema. Здесь мы для наглядности в качестве выражения выписываем их представление на естественном языке, а не номера слов (токенов) в словаре. Из второй аксиомы следует, что переводом выражения «Петя ходит в» на входном языке является выражение «Pit goes to the» и соответственно «зоопарк»-> «zoo», «кино» -> «cinema». Как видим, из приведенного примера выражения EI1 и EO1 могут иметь разные длины. Как переводятся фрагменты выражений EI1 по имеющейся информации и аксиоме **A2** установить невозможно.

Разбиение на две части для применения аксиомы **A2** возможно не всегда. Общие части описания внешней ситуации могут находиться не в самом начале или конце выражений. В этом случае аксиома **A2** не применима.

Петя ходит в зоопарк. Коля ходит в магазин.

Pit goes to the zoo. Nick goes to the shop.

В этом примере общие части описаний «ходит в» и «goes to the» находится в середине выражений. В этом случае можно установить соответствие между общими частями описаний на входном и выходном языках «ходит в» -> «goes to the».

Аналогично в середине выражений может находиться и различающаяся часть.

Петя ходит в зоопарк. Петя бегает в зоопарк.

Pit goes to the zoo. Pit run to the zoo.

В этом примере различающиеся части описаний «ходит» и «бегает» на входном языке и «goes» и «run» на выходном языке находятся в середине выражений. Между этими различными частями описаний можно установить соответствие «ходит»-> «goes», «бегает»-> «run». Эти правила установления соответствия сформулируем в виде новых аксиом обучения **A31** и **A32**.

Аксиома обучения A31. Пусть дано [(EI1,EI2,EI3);(EO1,EO2,EO3)] и [(EI4,EI2,EI5);(EO4,EO2,EO5)] тогда EI2->EO2. В приведенном выше примере было EI1= «Петя», EI2= «ходит в», EI3= «зоопарк», EI4= «Коля», EI5= «магазин», EO1= «Pit», EO2= «goes to the», EO3= «zoo», EO4= «Nick», EO5= «shop».

Аксиома обучения A32. Пусть дано [(EI1,EI2,EI3);(EO1,EO2,EO3)] и [(EI1,EI4,EI3);(EO1,EO4,EO3)] тогда EI2->EO2, EI4->EO4 . В приведенном выше примере было EI1=«Петя», EI2=«ходит», EI3=«в зоопарк», EI4=«бегает», EO1=«Pit», EO2=«goes», EO3=«to the zoo», EO4=«run».

Представление модели мира в виде графа

Модель мира удобно представлять в виде иерархического графа, вершины которого соответствуют выражениям или обобщенным понятиям (одинаково употребляющихся слов или выражений). Поскольку выражение представляет собой упорядоченную последовательность подвыражений, то выражениям соответствуют вершины, несущие информацию о порядке следования подвыражений. Такие вершины будем называть структурными вершинами, они несут информацию об общей структуре соответствующего естественного языка. Вершины, описывающие множество одинаково употребляемых выражений, будем называть вершинами конкретизации. Выбор и подстановка определенного выражения из всего множества одинаково употребляемых выражений фиксирует конкретную ситуацию из множества похожих. На языке графа модели мира аксиомы обучения и выделение обобщенной сущности могут быть описаны преобразованием графа.

Для решения задачи автоматического перевода используется представление модели мира на входном и выходном языках в виде графов с вершинами разных типов с установленными связями между этими графами. Граф описания модели мира представляет собой иерархическую структуру с вершинами трех типов для каждого (входного и выходного) языков. Вершины соединены между собой ссылками трех типов. Ссылки на более высокий уровень будем называть ссылками U (UP) типа, ссылки на более низкий уровень будем называть ссылками D (Down) типа, ссылки на часть графа на другом языке (на перевод) будем называть ссылками T (TRANSLATE)

типа. Каждой ссылке U типа соответствует ссылка D типа, соединяющая ту же пару вершин в обратном направлении, и каждой ссылке D типа соответствует ссылка U типа. Аналогичным образом каждой ссылке T типа соответствует ссылка T типа, идущая в обратном направлении. Ссылки U и D типов соединяют вершины графа, соответствующие одному и тому же языку описания, ссылки T типа соединяют вершины модели, соответствующие разным языкам описания. Вершины графа бывают трех типов. Вершина S типа (структурная, обозначена серым цветом) содержит информацию о порядке следования ссылок D типа на нижележащие вершины. Этот тип вершин может иметь сколько угодно ссылок каждого типа. Вершины K типа (конкретизации, обозначена темно серым цветом) содержат информацию о том, какие нижележащие вершины могут попадаться в описании конкретной ситуации на данном месте. Эти вершины так же могут содержать произвольное число ссылок каждого типа. Порядок ссылок для этого типа вершин значения не имеет. Вершины P типа (подстановки обозначены светло серым цветом) имеют ровно одну ссылку U типа и одну ссылку D типа. Ссылка U типа из вершины P типа указывает на вершину S типа или K типа, а ссылка D типа может указывать либо на вершину S типа, либо на вершину K типа.

Графическое представление аксиом построения модели мира

Аксиомы построения модели мира можно удобно изображать графически. При этом будем задавать два графика – начальную структуру (фрагменты графа модели мира до применения соответствующей аксиомы обучения) и конечную структуру, которая получается при применении правил преобразования этой аксиомы. Они будут отображать правила преобразования модели мира графическим способом.

В данной работе сформулируем аксиомы STAK31 и STAK32 (Stady axiom). Цифра 3 в названии аксиомы означает, что правило работает при разделении исходных выражений на три части. Аксиомы STAK31 и STAK32 добавляют к аксиомам **A31** и **A32** правила выделения обобщенной сущности (одинаково употребляющихся выражений). Эти аксиомы существенно ускоряют процесс обучения и уменьшают необходимый размер обучающего корпуса за счет обобщений.

Рис. 1 и 2 задают аксиому **STAK31.** Аксиома **STAK31** применяется только в том случае, если ни одна из вершин W31 --- W3p, W41-W4q не совпадает ни с одной из вершин W6i1 --- W6s, W71---W7t в графе на входном языке и нет аналогичных совпадений в дереве на выходном языке.

Рис. 1. Графическое представление исходных выражений
с общими частями описаний в середине выражений

Рис. 2. Результат применения аксиомы **STAK31**

Если r=1, то вершины WS5 и WP10 не создаются. Если p=1, t=1, q=1, s=1, то не создаются соответствующие вершины WS1, WS2, WS3, WS4. Аналогично и на части графа, соответствующей выходному языку. Здесь и далее для краткости не показаны ссылки T типа между исходными графами на входном и выходном языках (WPI10<->WPO10,WSI5<->WSO5,

WSI1<->WSO1), индексы I и O (входной и выходной язык) так же опущены. В левой части рисунка расположена часть графа на входном языке, а в правой части на выходном.

Рис. 3 и 4 задают аксиому **STAK32.** Аксиома **STAK32** применяется только в том случае, если ни одна из вершин W31 --- W3p не совпадает ни с одной из вершин W51 --- W5w в графе на входном языке и нет аналогичных совпадений в дереве на выходном языке.

Рис. 3. Графическое представление исходных выражений
с различающимися частями описаний в середине выражений

Если r=1, q=1, p=1, s=1 то соответствующие вершины WS7, WS8, WS10, WS12 не создаются. Для краткости на рисунке не обозначены ссылки T типа WSI1<->WSO1, WPI1<->WPO1, WKI9<->WKO9, WSI10<->WSO10, WSI12<->WSO12.

Аксиомы построения графа модели мира не зависят от выбора конкретных языков и используют только сходство и различия ситуаций во внешнем мире и их описаний на различных языках, поэтому с одинаковым успехом работают для любых языков. Каждый шаг преобразований легко объясним, так как соответствует выделению общих понятий и перестройке графа с

учетом этих обобщений. Полученная в результате последовательности таких объяснимых преобразований модель также обладает свойством объяснимости на всех этапах ее построения.

Рис. 4. Результат применения аксиомы **STAK32**

Выводы

В работе развит аксиоматический подход к автоматическому построению модели мира в виде графа. Сформулированы новые правила построения графа модели мира (обучения). Новые правила позволяют ускорить обучение и сократить размер корпуса обучающих текстов. Эта модель мира может использоваться системами автоматического перевода с одного естественного языка на другой. Алгоритм построения модели мира универсален и не зависит от выбора конкретных языков, но сам граф зависит от структуры выбранных языков. Процесс обучения состоит в подаче на вход системы пар выражений на входном и выходном языках. Построенная модель обладает свойством объяснимости.

Список литературы

1. Марчук Ю. Проблемы машинного перевода. М.: Наука, 1982. 233 с.
2. Cho K. Learning Phrase Representations using RNN Encoder-Decoder for Statistical Machine Translation // 2014. arXiv:1406.1078v3
3. Ilya Sutskever, Oriol Vinyals, Quoc V. Le Sequence to Sequence Learning with Neural Networks //2014 , arXiv:1409.3215

4. Kocmi T, Machacek D, Bojar O The reality of multi-lingual machine translation // 2022, arXiv:2202.12814

5. Makoto Nagao A framework of a mechanical translation between Japanese and English by analogy principle // Artificial and Human Intelligence. Elsevier Science Publishers. B.V / Ed. A. Elithorn and R. Banerji

6. GPT-4 Technical Report // 2023, arXiv:2303.08774v3

7. Анисимович К. и др. Синтаксический и семантический Парсер, основанный на лингвистических технологиях abbyy compreno. Abbyy. М., 2012.

8. Курьян В.Е. Моделирование процесса обучения человека с помощью построения графа модели мира // Учет и статистика. N4 (56). 2019.

9. Курьян В.Е. Алгоритм автоматического перевода текстов с помощью дерева модели мира // Учет и статистика. N1 (57). 2020.

10. Курьян В.Е. Автоматический перевод и граф модели мира // DOI 10.38006/907345-75-1.2020.305.309. ПРИМЕНЕНИЕ ТЕХНОЛОГИЙ ВИРТУАЛЬНОЙ РЕАЛЬНОСТИ И СМЕЖНЫХ ИНФОРМАЦИОННЫХ СИСТЕМ В МЕЖДИСЦИПЛИНАРНЫХ ЗАДАЧАХ FIT-M 2020. СБОРНИК ТЕЗИСОВ МЕЖДУНАРОДНОЙ НАУЧНОЙ КОНФЕРЕНЦИИ.

11. Курьян В.Е. Автоматический перевод на основе графа модели мира // Нейроинформатика 2021. XXIII Международная научно-техническая конференция. Сборник научных трудов. М.: МИФИ, 2021. С. 29–38.

12. Курьян В.Е. Моделирование процесса обучения человека. Аксиоматический подход // Нейроинформатика 2022. XXIV Международная научно-техническая конференция. Сборник научных трудов. М.: МФТИ, 2022. С. 260–269.

Секция

Нейроморфные вычисления и глубокое обучение

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

РЕАЛИЗАЦИЯ ПАМЯТИ ОБРАЗОВ В КЛАССЕ БЫСТРЫХ НЕЙРОННЫХ СЕТЕЙ

Рассматривается применение обратно-ориентированных пирамидальных нейронных сетей быстрого обучения для реализации элементов памяти образов. Сети рассматриваемого класса представимы линейными операторами, имеют самоподобную структуру и являются частным случаем алгоритма быстрого преобразования Фурье. Приведены методы топологического построения пирамидальных сетей. Показано, что пирамидальная сеть памяти обеспечивает хранение и восстановление образов подобно хранению чисел в компьютерной памяти произвольного доступа. Доказано, что пирамидальные сети относятся к категории сетей с глубокой степенью обучения.

Ключевые слова: *быстрая нейронная сети, память образов, пластичность, степени свободы.*

Введение

К нейронным сетям, реализующим память, относится большой класс нейронных сетей с обратными связями, включающий в себя сети Элмана [1], Хопфилда [2], Хэмминга [3], АРТ [4], и другие сети рекуррентного типа. Сети данного класса решают задачи восстановления искажённых образов, ассоциативной памяти, кратковременной динамической памяти и другие подобные задачи в контексте распознавания образов, задача сохранения и точного восстановления образа при этом не ставится.

В данной работе будут рассмотрены пирамидальные с сети с регулярной самоподобной структурой. Будет показано, что сети данного типа могут быть эффективно использованы для хранения и точного восстановления образов. Пирамидальные сети имеют глубокую связь с алгоритмом быстрого преобразования Фурье (БПФ), для обозначения нового класса сетей используется термин быстрые нейронные сети (БНС) [5].

Для БНС можно предложить быстрые алгоритмы обучения, абсолютно сходящиеся за конечное число шагов. В основе алгоритмов обучения БНС лежит доказанное свойство структурной фрактальности БПФ, которое можно выразить системным инвариантом морфологического уровня [6]. Идея метода обучения БНС к одной или нескольким функциям образов основана на факторизации каждой функции заданного набора в предфрактальное произведение, соответствующее мультипликативной форме представления элементов матрицы быстрого преобразования.

Построение пирамидальной сети памяти

Рассмотрим для определённости БНС в топологии «Кули-Тьюки с прореживанием во времени». В [7] показано, что топологическая модель сети данной топологии описывается символьными кортежами:

$$U^m = \langle u_{n-1}u_{n-2}\cdots u_{m+1}u_m v_{m-1}v_{m-2}\cdots v_1 v_0 \rangle,$$
$$V^m = \langle u_{n-1}u_{n-2}\cdots u_{m+1}v_m v_{m-1}v_{m-2}\cdots v_1 v_0 \rangle,$$
$$z^m = \langle u_{n-1}u_{n-2}\cdots u_{m+1}v_{m-1}v_{m-2}\cdots v_1 v_0 \rangle.$$

Здесь m – номер слоя, z^m – номер нейронного ядра в слое в слое m, локальные переменные u_m, v_m определяют позиционные номера рецепторов и аксонов нейронных ядер. Кортежи используются для поразрядного представления чисел в позиционной системе счисления. Например, для системы счисления с основанием 2 имеем:

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

Нумерация разрядных переменных начинается с нулевого значения, то же самое относится и к нумерации слоёв сети. В общем случае используется многоосновная система счисления, где разрядам u_i соответствуют основания p_i, а разрядам v_j основания g_j. Значения оснований определяют структурные характеристики БНС.

Нейронное ядро в слое m представляет собой матрицу синаптических весов $W_{z^m}^m = \left\| w_{z^m}^m \left(u_m, v_m\right) \right\|$ размерностью $p_m \times g_m$. В [7] показано, что для БНС элементы матрицы преобразования выражаются через элементы матриц нейронных ядер:

$$h\left(U,V\right) = w_{z^{n-1}}^{n-1}\left(u_{n-1}, v_{n-1}\right) w_{z^{n-2}}^{n-2}\left(u_{n-2}, v_{n-2}\right)\cdots w_{z^0}^{0}\left(u_0, v_0\right) \qquad (1)$$

Для построения пирамидальной сети выберем структурные характеристики следующим образом:

- размерности рецепторных полей сети положим равными $p_0 = p_1 = \cdots = p_{n-2} = 1, \quad p_{n-1} \neq 1$. В этом случае размерность сети по входу будет равна $N = p_{n-1}$;
- размерности аксоновых полей сети зададим произвольными положительными целыми числами $g_0, g_1, \cdots, g_{n-1}$. Размерность сети по выходу в этом случае будет равна $M = g_0 g_1 \cdots g_{n-1}$.

Топологическая модель при данных структурных характеристиках будет иметь вид:

$$U^m = \langle u_{n-1} 0_{n-2} \cdots 0_{m+1} 0_m v_{m-1} v_{m-2} \cdots v_1 v_0 \rangle,$$
$$V^m = \langle u_{n-1} 0_{n-2} \cdots 0_{m+1} v_m v_{m-1} v_{m-2} \cdots v_1 v_0 \rangle,$$
$$z^m = \langle u_{n-1} 0_{n-2} \cdots 0_{m+1} v_{m-1} v_{m-2} \cdots v_1 v_0 \rangle.$$

На рис. 1 показана топология сети для структурных характеристик $[p_0 p_1 p_2 p_3] = [1112]$, $[g_0 g_1 g_2 g_3] = [2222]$. Детали построения графа по топологической модели изложены в работе [7]. Пирамида расширяется от входа сети к выходу, поэтому в названии используется термин обратно-ориентированная пирамида.

Рис. 1. Обратно-ориентированная пирамидальная сеть для реализации памяти

Факторизация образов

Будем полагать, что образ, задан функцией $f(v)$ на дискретном интервале длиной $M = g_0 g_1 \ldots g_{n-1}$, где g_m – произвольные целые числа. Представим аргумент функции в позиционной многоосновной системе счисления с основаниями $g_0 g_1 \ldots g_{n-1}$. Формула перехода, как известно, имеет вид:

$$v = \langle v_{n-1} v_{n-2} \ldots v_0 \rangle = v_{n-1} g_{n-2} g_{n-3} \ldots g_0 + v_{n-2} g_{n-3} g_{n-4} \ldots g_0 + \ldots + v_1 g_0 + v_0.$$

где $v_i \in [0,1,\ldots g_i - 1]$ – разрядные переменные. В результате данного преобразования образ представляется как многомерная функция $f\langle v_{n-1} v_{n-2} \ldots v_0 \rangle$. Каждый аргумент функции определяет её некоторый масштабный срез. Зафиксируем все аргументы функции кроме v_m. Варьируя свободный аргумент v_m, получим выборку S_m (с числом элементов g_m). Фрактальным фильтром [7] частотной локализации m называется произвольный функционал $F(S_m)$, определённый на выборке S_m. Операцию фрактальной фильтрации можно записать в виде:

$$f_{out}\langle v_{n-1} v_{n-2} \ldots v_{m+1} v_{m-1} \ldots v_0 \rangle = \underset{v_m}{F}\left(f_{inp} \langle v_{n-1} v_{n-2} \ldots v_0 \rangle \right).$$

В простейшем варианте фрактальный фильтр выполняет, например, суммирование значений функции по аргументу v_m. Фрактальная фильтрация по аргументу v_m приводит к сокращению интервала определения функции в g_m раз. Рассмотрим цепочку фрактальных фильтров, показанную на рис. 2.

Рис. 2. Цепочка фрактальных фильтров

В этой цепочке фрактальная фильтрация образа начинается со старшего разряда v_{n-1}. Выходные сигналы фильтров цепочки определяются рекуррентным соотношением:

$$f_{m+1}\left\langle v_{n-m-2}\ldots v_0\right\rangle = \underset{v_{n-m-1}}{F}\left(f_m\left\langle v_{n-m-1}\ldots v_1 v_0\right\rangle\right).$$

Для цепочки фильтров рекуррентно введём функции:

$$\phi_{i^{n-m}}\left(v_{n-m}\right) = \frac{f_m\left\langle v_{n-m}v_{n-m-1}\ldots v_0\right\rangle}{f_{m+1}\left\langle v_{n-m-1}v_{n-m-2}\ldots v_0\right\rangle}, \qquad m = 1,2,\ldots n,$$

где $i^m = \left\langle v_{m-1}v_{m-2}\ldots v_1 v_0\right\rangle$. Используя определение функций, можно записать:

$$f\left(v\right) = f_0\left\langle v_{n-1}v_{n-2}\ldots v_0\right\rangle = \varphi_{i^{n-1}}\left(v_{n-1}\right)\varphi_{i^{n-2}}\left(v_{n-2}\right)\ldots\varphi_{i^1}\left(v_1\right)\varphi_{i^0}\left(v_0\right).$$

Сохранение образов в нейросетевой памяти

Пусть запоминаемые образы $y^k\left(V\right)$ представляет собой набор, состоящий из p_{n-1} дискретных функций, заданных на интервале длинной M, где k – порядковый номер функции. Выполним мультипликативную декомпозицию каждой функции по переменным v_i, начиная со старшего разряда, в результате получим:

$$y^k\left(V\right) = \varphi^k_{i^{n-1}}\left(v_{n-1}\right)\varphi^k_{i^{n-2}}\left(v_{n-2}\right)\cdots\varphi^k_{i^0}\left(v_0\right), \tag{2}$$

где $i^m = \left\langle v_{m-1}v_{m-2}\cdots v_1 v_0\right\rangle$. Сравнивая выражения (1) и (2) получим правило обучения нейронной сети для сохранения образов:

$$w^{n-1}_{z^{n-1}}\left(u_{n-1}, v_{n-1}\right) = \varphi^k_{i^{n-1}}\left(v_{n-1}\right) \quad \text{для } m = n-1,$$

$$w^m_{z^m}\left(0_m, v_m\right) = \varphi^k_{i^m}\left(v_m\right) \quad \text{для } m < n-1,$$

$$z^m = \left\langle u_{n-1}0_{n-2}\cdots 0_{m+1}v_{m-1}v_{m-2}\cdots v_1 v_0\right\rangle,$$

$$i^m = \left\langle v_{m-1}v_{m-2}\cdots v_1 v_0\right\rangle.$$

Предварительно, для упорядочивания хранимых функций, должно быть установлено взаимно-однозначное соответствие $k \Leftrightarrow u_{n-1}$ между порядковым номером функции и разрядной переменной u_{n-1}. Считывание памяти реализуется установкой на входе нейронной сети унитарного кода, в котором только один из разрядов равен 1, а остальные – нулю. Для сети, показанной на рис. 1 это будут комбинации $\left[0,1\right]$ или $\left[1,0\right]$. При использовании

кодов $[1,1]$ хранимые образы складываются, а при кодах $[1,-1]$ из первого образа вычитается второй. На рис. 3 показаны результаты считывания образов БНС-памяти, представляющих собой дискретные функции синуса, отличающиеся по частоте в два раза.

Рис. 3. Результаты считывания памяти, реализованной на пирамидальной БНС

Пластичность пирамидальной нейронной сети

В исследованиях нейробиологов термин «пластичность» используется, как качественная характеристика способности нейронной сети обучаться при воздействии внешних факторов. Для искусственных нейронных сетей адекватной количественной оценкой может служить число независимых настроек, существующих в сети. Это значение, как правило, меньше полного количества синаптических весов (исключением является однослойный персептрон, для которого соблюдается равенство).

В механике для оценки числа независимых координат используется понятие «число степеней свободы». Близкую аналогию можно провести и для нейронных сетей. В самом деле, нейронную сеть прямого распространения можно представить, как нелинейный оператор, преобразующий входной вектор в выходной. Полное множество операторов образует многообразие в многомерном пространстве, в котором каждый оператор сети можно рассматривать как некоторую материальную точку. Изменение синаптических весов нейронной сети приводит к перемещению точки-оператора в пространстве операторов. Следуя далее механической аналогии, будем называть число независимых координат, необходимое и достаточное для однозначного определения местоположения точки-оператора в пространстве

операторов, числом степеней свободы нейронной сети и рассматривать эту величину как количественную оценку пластичности сети.

Рис. 4. Структурная модель
обратно ориентированной пирамидальной нейронной сети

Расчёт степени пластичности БНС можно выполнить непосредственно по структурной модели сети. На рис. 4 представлена структурная модель для сети с топологией, показанной на рис. 1. Каждая вершина структурной модели является нейронным ядром, пара цифр, записанных в вершине, определяют размерность рецепторного и аксонового поля нейронного ядра, все связи между вершинами имеют ранги равные единице. В [7] получена формула расчёта числа степеней свободы БНС, которая имеет вид:

$$S(H)=\sum_{m=0}^{n-1} p_m g_m q_m - \sum_{m=0}^{n-2} D_m \,, \qquad (3)$$

где p_m, g_m размерности рецепторного и аксонового поля ядра в слое m, q_m – число ядер в слое, D_m – количество однoранговых связей в межслойном переходе с номером m. Используя (3), получим: $S(H)=(1\cdot 2)\cdot 14+(2\cdot 2)\cdot 8-28=32$. Данная нейронная сеть обеспечивает хранение двух произвольных дискретных функций, заданных на интервале длиной $M=16$. Для задания двух функций требуется определить 32 значения. Таким образом, сеть полностью использует свой потенциал для хранения функций и в этом смысле относится к категории сетей с глубокой степенью обучения.

Банк памяти на обратно ориентированной сети с коммутацией плоскостей

Дополним топологическую модель Кули-Тьюки «с прореживанием по времени» дополнительными плоскостями нейронных ядер, номера которых определим кортежем π_m:

$$U^m = \langle u_{n-1}u_{n-2}\cdots u_{m+1}u_m v_{m-1}v_{m-2}\cdots v_1 v_0 \rangle,$$
$$V^m = \langle u_{n-1}u_{n-2}\cdots u_{m+1}v_m v_{m-1}v_{m-2}\cdots v_1 v_0 \rangle,$$
$$z^m = \langle u_{n-1}u_{n-2}\cdots u_{m+1}v_{m-1}v_{m-2}\cdots v_1 v_0 \rangle,$$
$$\pi_m = \langle u_{m-1}u_{m-2}\cdots u_1 u_0 \rangle.$$

Максимальное количество дополнительных плоскостей появится в последнем слое. Номер плоскости в этом слое будет определяться кортежем $\pi_{n-1} = \langle u_{n-2}u_{n-3}\cdots u_1 u_0 \rangle$, а число плоскостей будет равно произведению оснований: $p_{n-2}p_{n-3}\cdots p_1 p_0$. По мере движения к входному слою число дополнительных плоскостей будет уменьшаться и для нулевого слоя имеем: $\pi_0 = \langle\ \rangle$, т.е. их не будет совсем, останется только одна плоскость базовой топологии. Таким образом, в новой топологии плоскость нулевого слоя останется прежней, а в старших слоях появятся дополнительные плоскости. На рис. 5 показана топологическая модель сети памяти со структурными характеристиками: $[p_0 p_1 p_2 p_3] = [2222]$, $[g_0 g_1 g_2 g_3] = [2222]$.

Рис. 5. Топологическая модель нейронной сети банка памяти

Будем полагать, что запоминаемые образы представлены в мультипликативной форме (2). В качестве образов могут использоваться произвольные функции, заданные на дискретном интервале длиной $M = g_0 g_1 \cdots g_{n-1}$. Запись образа в память, соответствует обучению нейронной сети. Для настройки нейронных ядер можно использовать базовое правило, вытекающее из обобщённой теоремы факторизации БНС, дополнив его номером плоскости:

$$w_{z^m}^m \left\langle \pi_m \right\rangle \left(u_m, v_m \right) = \varphi_{i^m}^k \left(v_m \right),$$

где k – порядковый номер функции, $V = \left\langle v_{n-1} v_{n-2} \cdots v_0 \right\rangle$ – точка выходной плоскости, $z^m = \left\langle u_{n-1} u_{n-2} \cdots u_{m+1} v_{m-1} v_{m-2} \cdots v_1 v_0 \right\rangle$ – номер настраиваемых ядер по слоям, $\pi_m = \left\langle u_{m-1} u_{m-2} \cdots u_1 u_0 \right\rangle$ – номер плоскости размещения ядер. Для $m = n-1$ имеем $z^{n-1} = i^{n-1} = \left\langle v_{n-2} v_{n-3} \cdots v_1 v_0 \right\rangle$, а варьируемыми переменными в левой части являются номер плоскости $\pi_{n-1} = \left\langle u_{n-2} u_{n-3} \cdots u_1 u_0 \right\rangle$ и разряд u_{n-1}. Вместе они покрывают весь диапазон координат входной плоскости. Этому диапазону отвечают возможные значения индекса k в правой части, отсюда следует, что каждая точка входной плоскости является активирующим адресом для хранимого образа. Т.е. построенная сеть обладает максимально возможной памятью, с адресным пространством, покрывающим всю входную плоскость, и, следовательно, является сетью памяти с глубокой степенью обучения.

К этому результату можно прийти, с другой стороны. С каждой выходной плоскостью $\pi_{n-1} = \left\langle u_{n-2} u_{n-3} \cdots u_1 u_0 \right\rangle$ связаны область ответственности во входной плоскости, определяемая схемой $U^0 = \left\langle u_{n-1} u_{n-2} \cdots u_1 u_0 \right\rangle$. Размер области определяется основанием разрядной переменной u_{n-1}. Нетрудно видеть, что выделенный сегмент вход-выход представляет собой пирамидальную обратно-ориентированную сеть памяти. Таким образом, вся сеть с коммутацией плоскостей представляет собой лес непересекающихся пирамидальных сетей памяти, упакованных в матричные структуры. Как было показано ранее пирамидальная сеть является сетью глубокого обучения, а значит и вся сеть с коммутацией плоскостей также является сетью глубокого обучения. Считывание памяти реализуется установкой на входе нейронной сети унитарного кода в области ответственности, каждой выходной плоскости. Хранимые образы воспроизводятся в выходных плоскостях сети. В любой выходной плоскости может воспроизводиться p_{n-1} образов, независимо

от воспроизведения хранимых образов в других областях. Сеть памяти, показанная на рис. 5 имеет 8 выходных плоскостей, с каждой плоскости можно считывать две функции. Таким образом, нейронная сеть обеспечивает хранение 16 произвольных функций, заданных на интервале длинной $M = 16$. Данная сеть имеет 256 степеней свободы.

При программной реализации нейронной сети и ограничении числа одновременно отображаемых образов до одного, можно реализовать считывание всех образов с одного выхода. Это достигается за счет неявного переключения плоскостей по значению адреса считывания U. Адрес считывания в поразрядном представлении имеет вид $U = \langle u_{n-1} u_{n-2} \cdots u_1 u_0 \rangle$, поэтому при считывании образа по данному адресу должны быть выбраны плоскости $\pi_m = \langle u_{m-1} u_{m-2} \cdots u_1 u_0 \rangle$, где m - номер слоя. Такой прием выделяет из сети только те нейронные цепи, которые ответственны за хранение данного образа, сокращая до минимума число вычислительных операций при его восстановлении. Альтернативно, образы можно считывать параллельно и независимо с каждой выходной плоскости.

Заключение

БНС являются частным случаем алгоритма быстрого преобразования Фурье (БПФ). Топологическая модель БПФ описывается символьными кортежами, которые позволяют реализовать выбор произвольных размерностей для базовых операций (нейронных ядер в терминах БНС). Это позволяет реализовать богатое разнообразие БНС для одной и той же топологической схемы. Среди возможных вариантов БНС, пирамидальная сеть отличается полным использованием степеней свободы, что делает ее эффективной в системах машинного обучения.

В памяти, реализованной на основе пирамидальных БНС, могут храниться двумерные и многомерные образы. В отличие от кристаллов цифровой памяти с последовательным хранением данных, где восстановление образа происходит за счет последовательного опроса ячеек, в памяти на БНС все пикселы образа восстанавливаются одновременно, что потенциально обеспечивает сверхвысокое быстродействие для памяти образов.

Список литературы

1. Elman, J.L. Finding structure in time. Cognitive Science. – 1990. – P. 179–211.
2. Hopfield, J. J. Neural networks and physical systems with emergent collective computational abilities, Proceedings of National Academy of Sciences, vol. 79, no. 8. P. 2554–2558, April 1982.

3. Richard Lippmann. 1987. An introduction to computing with neural nets. IEEE Assp magazine.

4. Carpenter, G.A. & Grossberg, S. (1987), ART 2: Self-organization of stable category recognition codes for analog input patterns. Applied Optics volume 26, number 23, December, 1987.

5. Дорогов, А. Ю. Быстрые нейронные сети: Проектирование, настройка, приложения. / А. Ю. Дорогов [Текст] // Лекции по нейроинформатике Ч.1. В тр. школы-семинара «Современные проблемы нейроинформатики», науч.-техн. конф. «Нейроинформатика-2004». 28–30 января 2004 г. – М.: МИФИ, 2004. – С. 69–135.

6. Дорогов А.Ю. Системные инварианты быстрых преобразований // Труды Четвертой межрегиональной школы семинара «Распределенные и кластерные вычисления», 14–16 сентября 2004 года, г. Красноярск.

7. Дорогов А.Ю. Теория и проектирование быстрых перестраиваемых преобразований и слабосвязанных нейронных сетей. СПб.: Политехника, 2014. – 328 с.

Н.В. ЧАПЛИНСКАЯ, Н.И. БАЗЕНКОВ

Институт проблем управления им. В.А. Трапезникова РАН, Москва

nadya1462@gmail.com

ОБУЧЕНИЕ ИМПУЛЬСНОЙ НЕЙРОННОЙ СЕТИ ЗА СЧЕТ МЕХАНИЗМОВ МИЕЛИНИЗАЦИИ И ДЕМИЕЛИНИЗАЦИИ

В работе рассматривается модель импульсной нейронной сети с пластичной миелиновой оболочкой аксонов, способная регулировать аксональные задержки в распространении спайков за счет процессов миелинизации и демиелинизации. Предложенный механизм синхронизирует реакции постсинаптического нейрона на поступающие спайки и способствует запоминанию нейронами демонстрируемых паттернов. Смоделированная импульсная нейронная сеть была успешно обучена распознавать рукописные цифры датасета USPS.

Ключевые слова: *спайковые нейронные сети, пластичность миелиновой оболочки аксонов, обучение без учителя, распознавание образов.*

Введение

Импульсные нейронные сети – наиболее биологически правдоподобные искусственные нейронные сети, в которых нейроны обмениваются короткими импульсами одинаковой амплитуды, спайками. Наиболее распространенный принцип обучения импульсных нейронных сетей – обучение

путем изменения весов синапсов – основан на биологическом эффекте синаптической пластичности. Однако недавние исследования показывают, что не менее важным фактором, влияющим на обучение биологических нейронных сетей и формирующим эффект памяти, является пластичность миелиновой оболочки аксонов [1]. Миелин, намотанный на аксон нейрона, не статичен, а способен активно наслаиваться и расслаиваться даже у взрослых [2], формируя процессы миелинизации и демиелинизации, и определяя задержки в распространении спайков по аксонам. Кроме того, задержки распространения спайков играют заметную роль в обработке нейронной информации. В слуховой системе птиц проблема локализации шума решается специальными дендритными структурами, точно настроенными на определенные задержки распространения сигнала [3]. Разница во времени между сигналами, поступающими от левого и правого уха, позволяет локализовать направление шума.

В [4] изучалась вычислительная мощность импульсных нейронов с программируемыми задержками. Авторы доказали, что очень простой нейрон с пластическими задержками вычислительно мощнее порогового нейрона и примерно эквивалентен нейрону с сигмовидной функцией активации. Они также показали, что размерность Вапника-Червоненкиса спайковой сети с программируемыми задержками квадратична по количеству нейронов, даже если веса фиксированы. Это означает, что SNN с пластическими задержками потенциально способна классифицировать сложные паттерны так же, как и ANN с сигмовидными нейронами.

Существуют некоторые исследования синаптических задержек в алгоритмах обучения импульсных нейронных сетей. В статье [5] пластичность задержки использовалась на выходном слое сети, в то время как первый скрытый слой обучался с помощью обычной пластичности весов синапсов. В работе [6] был предложен градиентный алгоритм обучения с задержками, который использовался в аппаратном датчике локализации звука. В [7] для предсказания направления движения точки использовалась комбинация принципов пластичности весов и задержек. В статье [8] изучается влияние аксональных задержек на синхронизацию спайков в сети. При этом в данной работе сеть обучается путем изменения весов синапсов стандартным методом STDP, а задержки считаются равными и фиксированными для одного процесса обучения. В статье [9] сеть обучается также с использованием правила STDP, но на основе аксональных задержек, причем сеть рассматривается в трехмерном пространстве, где аксоны имеют разную длину.

Данная работа предлагает новый алгоритм обучения, основанный на пластичности аксональных задержек. Наша работа отличается от вышепе-

речисленных следующими моментами. Во-первых, мы моделируем изменения задержки в результате сложной динамики миелина, регулируемой выходным нейроном. Во-вторых, предложенное нами правило обучения работает вне зависимости от спайка выходного нейрона, что частично решает проблему «молчащих» нейронов, которые никогда не генерируют спайки и, следовательно, никогда не участвуют в обучении.

При помощи предложенного механизма, мы обучили однослойную импульсную нейронную сеть распознавать изображения рукописных цифр датасета USPS [10]. Сеть оказалась способна запоминать характерные особенности изображений и использовать их для классификации.

Результат работы демонстрирует, что механизм пластичности миелиновой оболочки аксонов можно использовать для решения задач обучения нейронных сетей.

Модель пластичности миелиновой оболочки аксона

Рассмотрим полносвязную импульсную нейронную сеть, состоящую из n нейронов на входе и m нейронов на выходе. На $n \cdot m$ аксональных ветвях входных нейронов имеется некоторое количество миелина, определяющее задержки в распространении спайков по соответствующим ветвям.

Выходные нейроны представлены моделью leaky-integrate-and-fire (LIF) с учетом проводимостей синапсов $g_{ij}(t)$:

$$\tau \frac{dv_j(t)}{dt} = v_{rest} - v_j(t) + \sum_{i=1}^{n} g_{ij}(t)\left(E_{exc} - v_j(t)\right), \qquad j = \overline{1,m}.$$

Синаптическая проводимость в данном случае определяется как

$$g_{ij}(t) = g_{amp} \mathrm{e}^{\frac{tf_{ij}-t}{\tau_s}} H\left(t - tf_{ij}\right),$$

где tf_{ij} – момент прибытия спайка, сгенерированным входным нейроном i, в синапс нейрона j, то есть с учетом задержки на соответствующей аксональной ветви. Таким образом, изменяя задержки на аксональных ветвях входных нейронов, можно управлять временами нарастания мембранного потенциала выходных нейронов сети.

В представляемой модели задержка $\sigma_{ij}(t)$ на аксональной ветви, соединяющей нейроны i и j, зависит от толщины миелиновой оболочки $m_{ij}(t)$ данной ветви по линейному правилу:

$$\sigma_{ij}(t) = \frac{\sigma_{max} m_{max} + \sigma_{\min} m_{min}}{m_{max} - m_{min}} - \frac{\sigma_{max} - \sigma_{\min}}{m_{max} - m_{min}} m_{ij}(t).$$

Здесь σ_{max}, $\sigma_{\min}$, m_{max}, m_{min} – максимальные и минимальные возможные значения задержки и толщины миелина аксональной ветви. При моделировании работы сети использовались значения $\sigma_{max} = 8$ мс, $\sigma_{\min} = 0.5$ мс, $m_{max} = 4$ мкм, $m_{min} = 0.3$ мкм. Данные аксональных задержек спайков соответствуют результатам работы [11] области LIP-FEF кортико-кортикальной системы обезьяны, данные толщины миелиновой оболочки взяты из исследования [12].

Введем характеристику $\bar{\mu}_j(t)$ выходного нейрона j, отвечающую за миелинизацию всех входящих аксональных ветвей, и характеристику $\mu_{ij}(t)$ синапса, соединяющего входной нейрон i с выходным нейроном j, отвечающую за демиелинизацию соответствующей аксональной ветви. В представляемой модели $\bar{\mu}_j(t)$ будет определять скорость наслаивания миелина (уменьшение задержки), а $\mu_{ij}(t)$ − скорость расслаивания миелина (увеличения задержки). Когда спайк достигает выходного нейрона, характеристики $\bar{\mu}_j(t)$ и $\mu_{ij}(t)$ рассчитываются следующим образом:

$$\begin{cases} \mu_{ij}(t) = \mu_{amp} H\left(t - tf_{ij}\right), \\ \bar{\mu}_j(t) = \dfrac{1}{n}\sum_{i=1}^{N} \mu_{ij}(t), \end{cases}$$

где $H(\cdot)$ – функция Хевисайда.

В свою очередь, изменение толщины миелиновой оболочки $m_{ij}(t)$ аксональной ветви зависит от разности значений $\bar{\mu}_j(t)$ и $\mu_{ij}(t)$ и определяет механизм обучения выходного нейрона j (со скоростью обучения k_j) рассматриваемой импульсной нейронной сети:

$$\frac{d}{dt} m_{ij}(t) = k_j \left|\bar{\mu}_j(t) - \mu_{ij}(t)\right| \left(H\left(\bar{\mu}_j(t) - \mu_{ij}(t)\right) - \frac{m_{ij}(t) - m_{min}}{m_{max} - m_{min}} \right).$$

Таким образом, для всех аксональных ветвей, по которым уже прошел спайк, толщина миелиновой оболочки уменьшится, а дальнейшие спайки по этим ветвям будут проходить медленнее. Для всех аксональных ветвей, по которым спайк еще не прошел, толщина миелиновой оболочки увеличится, увеличивая и скорость распространения спайков по данным ветвям.

После нескольких итераций входящие спайки начнут приходить на выходные нейроны почти синхронно, что приведет к сильному нарастанию мембранных потенциалов и последующей реакции одного из выходных нейронов, что может быть интерпретировано как запоминание нейроном демонстрируемого паттерна.

Архитектура и процесс обучения сети

В данной работе используется широко известная сетевая архитектура «победитель получает все» (WTA). Сеть состоит из входного слоя нейронов-сенсоров и выходного слоя обучающихся нейронов. Нейроны входного и входного слоя связаны возбуждающими, при этом нейроны выходного слоя так же обладают латеральными подавляющими связями с тормозящими синапсами, обеспечивающими конкуренцию нейронов выходного слоя за демонстрируемый паттерн. Обучившийся раньше всех нейрон-победитель генерирует спайк, благодаря которому в проигравших нейронах срабатывает механизм забывания: значение толщины миелина на ветвях аксонов, соединяющихся с этими выходными нейронами, возвращается к своему значению до обучения при текущем воздействии.

Поскольку в правиле обучения используются данные о временах генерации спайков входными нейронами, для паттернов лучше всего подходит временное кодирование, а именно кодирование по времени первого спайка (TTFS). В случае изображений TTFS работает следующим образом: при текущей экспозиции изображения входной нейрон, соответствующий самому светлому пикселю, генерирует спайк первым, входной нейрон, соответствующий самому темному пикселю, генерирует спайк последним. Времена генерации спайков остальными нейронами в данной работе рассчитываются линейно.

Изображения обучающей выборки экспонируются поочередно, и при каждом экспонировании нейроны-сенсоры несколько раз генерируют последовательности спайков, соответствующие закодированному паттерну. Таким образом, при каждом воздействии все выходные нейроны будут, согласно описанному правилу обучения, корректировать толщину миелина на входящих аксональных ветвях, чтобы в конечном итоге сгенерировать собственные спайки как реакцию сети на данный паттерн.

После обучения полученные значения толщины миелина на разветвлениях аксонов фиксировались и далее проводились классификация модели на обучающей выборке и тестирование модели на обучающей и тестовой выборках. При классификации и тестировании, каждое изображение, подаваемое на вход сети, экспонировалось при помощи одной последовательности спайков (результата TTFS кодирования данного изображения).

Результаты обучения

В качестве демонстрационного примера корректной работы представленного правила обучения рассмотрим решение задачи распознавания

изображений датасета USPS. Датасет содержит 9298 изображений рукописных цифр от 0 до 9 размера 16 на 16 пикселей.

Ввиду описанных в предыдущем разделе рассуждений, для решения задачи распознавания образов на датасете USPS спайковая нейронная сеть должна состоять из 256 нейронов входного слоя и не менее 10 нейронов выходного слоя с латеральными подавляющими связями. Количество нейронов на выходном слое сети является важным гиперпараметром, который, как будет показано далее, существенным образом влияет на качество обучения сети на данном датасете.

В данной работе была исследована зависимость значения F1-меры на обучающей и тестовой выборках от числа выходных нейронов сети. Результат исследования представлен в виде соответствующих графиков (рис. 1).

Рис. 1. График, иллюстрирующий зависимость значения F1-меры на обучающей и тестовой выборках от количества нейронов выходного слоя сети

Несмотря на значительную флуктуацию результатов экспериментов, обусловленную стохастичностью начальных состояний сети для каждого нейрона, легко видеть, что значение F1-меры растет. Если на 20 нейронах значение F1-меры на обучающей и на тестовой выборке 0.24 и 0.15 соответственно, то на 300 нейронах имеем лучший результат в представленном диапазоне: 0.7 на обучающей выборке (2172 изображений) и 0.643 на тестовой выборке (300 изображений).

Также интересным представляется результат классификации, а именно, то, в каком соотношении распределились нейроны выходного слоя по реакции на изображения разных классов. В эксперименте с 300 нейронами

выходного слоя лишь 8 нейронов не смогли среагировать ни на одно изображение обучающей выборки. Наибольшее число нейронов (43 и 42 нейрона) понадобилось для запоминания цифр 2 и 3, а наименьшее (6 и 15 нейронов) понадобилось для запоминания цифр 1 и 9. Это может говорить о том, что в обучающем наборе похожие изображения цифр 1 и 9 (со значительной площадью пересечения, достаточной для запоминания одним нейроном) встречаются существенно чаще, чем для цифр 2 и 3. Результат классификации нейронов можно наблюдать на гистограмме ниже (рис. 2).

Рис. 2. Классификация нейронов выходного слоя в соответствии с реакцией на изображения обучающей выборки в сети с 300 нейронами

Заключение

Импульсные нейронные сети, работающие на нейроморфных чипах, − многообещающая технология, которая может привести к созданию систем искусственного интеллекта следующего поколения. Основной проблемой в этой области является отсутствие биологически правдоподобных алгоритмов обучения, эффективность которых была бы столь же высока, как у глубоких нейронных сетей. Одна из причин этого заключается в том, что большинство методов обучения импульсных нейронных сетей фокусируются на обновлении синаптических весов и опускают другие процессы, формирующие обучение биологических нейронных сетей. В данной работе исследуется влияние пластичности миелиновой оболочки аксонов на возможность обучения сети.

Представленное правило обучения основано на изменении задержек в распространении спайков по аксону за счет процессов миелинизации и демиелинизации аксона. Во время обучения каждый нейрон регулирует толщину миелиновой оболочки на входящих аксональных ветвях таким образом, чтобы добиться синхронизации поступающих на его синапсы спайков.

Мы изучили эффективность предложенного подхода в задаче распознавания изображений набора данных USPS. Изображения были представлены сети, которая выявила характерные особенности паттернов с помощью предложенного правила аксональной пластичности. Затем извлеченные признаки использовались для обучения модели задаче классификации. В наших экспериментах сеть успешно запоминала особенности изображений, имеющих в качестве переменных параметров только задержки.

Результаты проделанной работы показали, что изменение задержек в распространении спайков по аксонам может быть рассмотрено в качестве надежной основы для обучения импульсных нейронных сетей в дополнение к обучению пластичностью синаптических весов. На основе данного и последующих исследований в дальнейшем могут быть созданы новые когнитивные архитектуры, в которых обучение будет двухмерным: пространственная информация будет храниться в весах, а информация, связанная со временем, будет храниться в задержках.

Список литературы

1. Fields R.D., Bukalo O. Myelin makes memories // Nature neuroscience. – 2020. – Т. 23. – №. 4. – С. 469–470.
2. Dutta D.J. et al. Regulation of myelin structure and conduction velocity by perinodal astrocytes // Proceedings of the National Academy of Sciences. – 2018. – Т. 115. – №. 46. – С. 11832–11837.
3. London M., Häusser M. Dendritic computation // Annu. Rev. Neurosci. – 2005. – Т. 28. – С. 503–532.
4. Maass W., Schmitt M. On the complexity of learning for spiking neurons with temporal coding // Information and Computation. – 1999. – Т. 153. – №. 1. – С. 26–46.
5. Paugam-Moisy H., Martinez R., Bengio S. Delay learning and polychronization for reservoir computing // Neurocomputing. – 2008. – Т. 71. – №. 7-9. – С. 1143–1158.
6. Oubari O. Precise timing and computationally efficient learning in neuromorphic systems : дис. – Sorbonne université, 2020.
7. Nadafian A., Ganjtabesh M. Bio-plausible Unsupervised Delay Learning for Extracting Temporal Features in Spiking Neural Networks // arXiv preprint arXiv:2011.09380. – 2020.
8. Khoshkhou M., Montakhab A. Spike-timing-dependent plasticity with axonal delay tunes networks of izhikevich neurons to the edge of synchronization transition with scale-free avalanches // Frontiers in systems neuroscience. – 2019. – Т. 13. – С. 73.

9. Talidou A. et al. Learning to be on time: temporal coordination of neural dynamics by activity-dependent myelination //bioRxiv. – 2021. – С. 2021.08. 17.456520.

10. Hull J.J. A database for handwritten text recognition research // IEEE Transactions on pattern analysis and machine intelligence. – 1994. – Т. 16. – №. 5. – С. 550–554.

11. Ferraina S., Paré M., Wurtz R.H. Comparison of cortico-cortical and cortico-collicular signals for the generation of saccadic eye movements // Journal of neurophysiology. – 2002. – Т. 87. – №. 2. – С. 845–858.

12. FitzGibbon T., Nestorovski Z. Human intraretinal myelination: Axon diameters and axon/myelin thickness ratios // Indian journal of ophthalmology. – 2013. – Т. 61. – №. 10. – С. 567.

М.В. ТАРАНИН, С.В. ТАРАНИН
АО НТЦ «Модуль»
taranin@module.ru

МОДЕЛЬ ЦВЕТНОЙ СПАЙКОВОЙ ВИДЕОКАМЕРЫ

Предложена пространственно-временная модель цветной спайковой видеокамеры для применения в нейроморфных системах. Модель имитирует работу цвето-оппонентных ганглиозных клеток сетчатки P-типа. Реализованы основные этапы обработки информации, которые происходят в сетчатке приматов. Эти этапы включают в себя многомасштабную пространственную фильтрацию при помощи цвето-оппонентных фильтров, имитацию микроскопических движений глаза и временную фильтрацию. Видеокамера может быть альтернативой DVS сенсорам.

Ключевые слова: *нейроморфные вычисления, спайковая камера, ганглиозные клетки, окулярный дрифт, цветооппонентность*.

Введение

Прогресс в создании нейроморфных систем, которые используют спайковые нейронные сети для своей работы, невозможен без появления сенсоров для получения информации о внешнем мире. Данная работа посвящена разработке оптического видео-сенсора, который является источником видеоинформации для спайковых вычислений и может быть разработан на существующей электронной базе.

В настоящее время единственным доступным спайковым видео-сенсором является DVS (Dynamic Vision Sensor) камера, которая переводит из-

менения яркости на изображении в последовательность спайков. DVS камеры стали очень популярны из-за высокого временного разрешения, малого энергопотребления и низкого битрейта по сравнению с обычными высокоскоростными камерами [1]. Однако они имеют ряд недостатков, которые ограничивают их применение как в системах технического зрения, так и при создании интерфейсов с биологическими системами. Для DVS камер можно выделить следующие ограничения:

1. Реагируют только на движущиеся объекты.

2. Не соответствуют современным моделям сетчатки глаза человека и животных.

3. Не реализованы универсальные алгоритмы начальной стадии обработки визуальной информации.

4. Нет возможности работать с цветными изображениями.

В предыдущей работе [2] нами была предложена пространственно-временная модель черно-белой спайковой видеокамеры, которая позволяет преодолеть первые 3 ограничения DVS камеры. Данная статья в основном посвящена созданию модели цветного видеосенсора и преодолению 4 ограничения. Кроме того, более подробно описываются ряд вопросов, которые не были отмечены в предыдущей статье.

В качестве биологического прообраза модели спайковой камеры были выбраны ганглиозные клетки сетчатки человека P – типа [3]. Анатомически эти клетки соответствуют карликовым (миджетным) клеткам сетчатки. Их доля составляет 80% от общего числа ганглиозных клеток. Они имеют наименьшие размеры рецептивных полей по сравнению с другими клетками и традиционно считаются ответственными за остроту восприятия. Рецептивные поля этих клеток проявляют цвето-оппонентность и позволяют работать с цветовой входной информацией. На вход P-клеток поступает информация от колбочек сетчатки, которые чувствительны к красному (L) и зеленому (M) участкам спектра. Также были обнаружены клетки, получающие вход от синего (S) участка спектра [3]. Таким образом, модель, которая имитирует работу ганглиозных клеток P-типа, позволяет решить задачу цветного зрения в пределах восприятия человека и приматов. Еще одним полезным свойством P-клеток является линейный отклик на изменения локального контраста сцены [4]. Это позволяет использовать линейные методы при моделировании их работы.

Сама модель состоит из следующих стадий:

1. Имитация микроскопических движений глаза, в частности, окулярного дрифта.

2. Многомасштабная пространственная фильтрация при помощи цвето-оппонентных фильтров.

3. Временная фильтрация при помощи банка низкочастотных фильтров и одного высокочастотного фильтра.

4. Преобразование полученного выходного сигнала в последовательность спайков при помощи генератора спайков.

Далее мы рассмотрим все стадии предложенной модели. Подробнее остановимся на пространственной фильтрации при помощи цвето-оппонентных фильтров, так как она напрямую связана с реализацией цветовосприятия у человека и детектирования хроматических градиентов на изображении. Остальные стадии обработки достаточно подробно изложены в статье [2].

Имитация окулярного дрифта

Человеческий глаз непрерывно совершает микроскопические движения, даже во время фиксации взгляда на объекте визуальной сцены [5]. Эти микродвижения во время фиксации между крупными скачками (саккадами) называются окулярным дрифтом и длятся около 10 мс, вызывая смещения на величину порядка 0.05□. Окулярный дрифт играет важную роль в начальной обработке визуальной информации. В частности, он совместно с временной фильтрацией обеспечивает декорреляцию выходного сигнала сетчатки [6]. Декорреляция позволяет сократить объем передаваемой информации и обеспечивает эффективное кодирование. Долгое время считалось, что эффективное кодирование является следствием пространственной фильтрации при помощи DoG-фильтров (Difference of Gaussians), которые представляют собой разность гауссианов для центра и периферии рецептивного поля клетки [7]. Однако позднее было показано, что уровня декорреляции, который был получен экспериментально, невозможно достичь только при помощи DoG-фильтров [6, 8]. Окулярный дрифт переводит пространственную информацию во временной домен. После чего применяется серия низкочастотных фильтров и один высокочастотный фильтр, которые выравнивают энергетический спектр сигнала путем увеличения доли высоких частот. В пространственном домене этот процесс приводит к декорреляции входного изображения [9].

В работе [9] показано, что окулярный дрифт можно имитировать двумерным броуновским движением. В данной работе мы вычисляем броуновское смещение по формуле:

$$s = (\sqrt{2Dt})N(0,1)\,. \qquad (1)$$

Здесь s – смещение за один шаг, t – длительность одного шага в секундах, D – коэффициент диффузии и $N(0,1)$ – двумерное нормальное распределение. Коэффициент диффузии выбирается равным $D = 20 arc\min^2 / s$ как в работе [9].

Общая схема применения процедуры дрифта выглядит следующим образом. Экспериментально получено, что время фиксации глазного яблока составляет ~ 200–300 мс и временная частота составляет 100 Гц [8]. В этой модели мы выбираем общее время фиксации равным 200 мс, время одного шага при частоте 100 Гц составит 10 мс. Всего за время дрифта нам нужно сделать 20 шагов. Таким образом, мы подвергаем входное изображение последовательно небольшим трансляциям. В результате получается 20 изображений, смещенных относительно друг друга, которые являются входными данными для последующих стадий обработки. Имитация дрифта представлена на рис. 1.

Рис. 1. Имитация окулярного дрифта

Многомасштабная пространственная фильтрация и цвет

Большинство ганглиозных клеток сетчатки P-типа проявляют пространственную и цветовую оппонентность [10]. Рецептивные поля этих клеток представляют собой антагонистические центр и окружение. Такая организация позволяет решать множество задач начальной обработки видеоинформации. К этим задачам можно отнести эффективное кодирование или удаление избыточности, многомасштабный анализ, удаление высокочастотных пространственных шумов и обеспечение цветового зрения.

Цветовая оппонентность реализуется настройкой центра рецептивного поля и окружения на различные цветовые каналы. Согласно цвето-оппонентной теории Геринга [11], для цветового зрения человека необходимо

наличие трех цветоразностных каналов: красно-зеленый (R-G), желто-синий (Y-B) и черно-белый (B-W). Наибольшее количество P-клеток реализуют красно-зеленый канал [12]. В этом случае центр получает входы от колбочек L-типа (или M-типа), а периферия от M-типа (соответственно L-типа). Такие клетки обозначаются L/M и M/L соответственно. Всего возможно 4 комбинации: L+/M-, L-/M+, M+/L- и M-/L+. Здесь знак соответствует клеткам ON (+) и OFF (-) типа.

Ответственными за Y-B канал долгое время считались ганглиозные клетки K-типа, но в работе [3] сообщается о существовании P-клеток, которые имеют S-(M+L) организацию, соответствующую Y-B каналу.

Классическая цвето-оппонентная теория считает, что черно-белый канал реализуется при помощи ахроматических ганглиозных клеток, которые получают вход от палочек сетчатки. Они реагируют только на яркость и не чувствительны к цвету [13]. Сетчатка содержит порядка 10 различных типов клеток, которые могли бы подойти на эту роль, однако анатомические исследования показали, что для обеспечения остроты зрения, которой обладает человек, только ганглиозные клетки P-типа могут быть кандидатами на роль ахроматических детекторов [14]. Таким образом, P-клетки задействованы для решения двух различных задач. С одной стороны, это единственные ганглиозные клетки с достаточно высокой пространственной плотностью и малыми рецептивными полями (центр может состоять из одной колбочки). Это позволяет объяснить высокую остроту зрения у человека для черно-белых изображений. С другой стороны, это единственные клетки, которые обладают спектральной оппонентностью, которая необходима для объяснения цветового зрения. Поэтому мы будем строить модель, которая использует P-клетки как для цветных каналов, так и для черно-белого канала.

В настоящее время существуют два основных подхода для решения этой задачи: мультиплексные модели и параллельные модели [15]. Мультиплексный подход основан на предположении, что каждая индивидуальная P-клетка переносит информацию одновременно для цветного зрения и ахроматического пространственного зрения. Эта информация разделяется или де-мультиплексируется уже в коре головного мозга. Возможная схема разделения цветной и яркостной (черно-белой) информации представлена на рис. 2.

Рис. 2. Схема «де-мультиплексирования» цветной и черно-белой информации

При сложении сигналов от L/M и M/L каналов мы получаем яркостной или ахроматический детектор, при вычитании мы получаем «дважды оппонентную» клетку, которая традиционно считается детектором для канала R-G [11]. Однако для полной цветопередачи нам необходим еще канал B-Y. Поэтому в этой модели вводят дополнительный механизм, который объединяет каналы R-G и B-Y. Этот дополнительный механизм вызывает наибольшую критику [15]. Дело в том, что в центральной ямке глаза, где острота зрения максимальна и располагается наибольшее количество L/M и M/L ганглиозных клеток, плотность S/(M+L) клеток является очень низкой [3]. Поэтому в коре головного мозга потребуется сложная схема соединений, если связывать выход каждой L/M или M/L клетки с синим каналом. Также малая плотность S/(M+L) неизбежно приведет к потере пространственного разрешения при слиянии каналов. Кроме того, в коре головного мозга не было обнаружено клеток, отвечающих за этот процесс. Поэтому была предложена модель параллельной обработки цветовой информации.

Параллельная модель [16] предполагает, что существуют ганглиозные клетки P-типа в сетчатке человека, которые получают входы от всех трех типов колбочек. Поэтому объединение разных каналов и получение цветоразностной схемы, которая соответствует восприятию человека, осуществляется уже на ранних этапах в сетчатке глаза. При этом для черно-белых краев используются обычные L/M и M/L клетки. Кандидатами на роль цветовых детекторов являются L/M и M/L клетки, которые получают вклад в периферию от колбочек S-типа. Возможные варианты L/(M+S) и M/(L+S).

Такая схема позволила построить цветоразностную модель, которая соответствует теории Геринга. Также теория успешно предсказывает положения «нулевых» точек, когда R-G или B-Y каналы обращаются в нуль. Еще одним следствием этой теории является то, что пространственное разрешение системы цветопередачи должно быть существенно ниже, чем у системы черно-белого зрения и определяться плотностью S-колбочек в сетчатке. Однако существование таких клеток до сих пор не подтверждено экспериментально. Кроме того, если для детекции краев используются только L/M и M/L клетки, то для цветного диффузного света мы будем получать ложные срабатывания.

Мы считаем, что задача цветового зрения разбивается на две подзадачи. Первая подзадача имеет дело с выделением краев объектов. При этом края могут быть как черно-белыми, так и цветными. Для надежного детектирования краев нам нужна схема, соответствующая рис. 2, как это следует из теории мультиплексирования. Несмотря на хроматическую составляющую в этой схеме, детектор позволяет определить только наличие края без указания цвета, т.к. для полного определения цвета нам нужен еще один канал. Следует также отметить, что S/(M+L) канал также используется для определения краев в своей части спектра и для него также строится схема из рис. 2. Вторая подзадача связана непосредственно с определением цвета. Параллельная теория кажется наиболее подходящей для этой цели, так как дает предсказания, совпадающие с измерениями чувствительности человека к цвету [16]. Эта теория предполагает наличие отдельного класса P-клеток, которые получают входы от колбочек всех трех типов.

В данной работе реализована только первая подзадача. Для реализации второй подзадачи необходимо больше знаний о параллельном канале. В частности, необходимо экспериментальное обнаружение P-клеток, получающих сигналы от всех трех колбочек сетчатки.

Рецептивные поля P-клеток моделируются при помощи DoG-фильтров. В пространственно-частотном домене отклик для центра и периферии определяется формулами [17]:

$$R_c(v) = CK_c \pi r_c^2 \exp(-\pi r_c^2 v^2), \quad (2)$$

$$R_s(v) = CK_s \pi r_s^2 \exp(-\pi r_s^2 v^2). \quad (3)$$

Здесь C − контраст (%), K_c и K_s − пиковая чувствительность для центра и окружения, ($imp * \sec^{-1} * contrast^{-1} * \deg^{-1}$), r_c и r_s − радиус центра и окружения соответственно (deg), v − пространственная частота (c* $\deg^{-1}$).

В работе [17] приводятся значения параметров (медиана) для клеток, расположенных на разном удалении от центральной ямки. Всего получаем

пять масштабов ($0^o - 5^o$, $5^o - 10^o$, $10^o - 20^o$, $20^o - 30^o$, $30^o - 40^o$). Для каждого масштаба вычисляем DoG-фильтр $R_c(v) - R_s(v)$. При этом для центра и периферии выбираются разные плоскости входного цветного изображения (RGB). Всего получаются следующие комбинации: r+g-, g+r-, r-g+, g-r+. Для сине-желтого канала получаем b+y-, y+b-, b-y+, y-b+. Таким образом, для каждого масштаба формируются восемь выходных каналов. Результат обработки для одного шага дрифта показан на рис. 3.

Рис 3. Многомасштабная пространственная фильтрация

Временная фильтрация и генерация спайков

Временная фильтрация осуществляется при помощи банка низкочастотных фильтров и одного высокочастотного [2]. Последовательность кадров, полученная после процедуры, имитирующей окулярный дрифт, представляет собой временной сигнал, который и подвергается фильтрации. Основная задача временной фильтрации – более глубокая декорреляции входного сигнала. Временной профиль центра рецептивного поля можно вычислить как обратное Фурье-преобразование частотного отклика следующей функции:

$$K(\omega) = \pm A e^{-i\omega D}\left(1 - \frac{H_s}{1 + i\omega\tau_S}\right)\left(\frac{1}{1 + i\omega\tau_L}\right)^{N_L}. \qquad (4)$$

Здесь $K(\omega)$ – частотный отклик на синусоидальную решетку с частотой ω, A – нормировочная константа, D – константа, определяющая задержку передачи данных по аксону, H_s – константа, определяющая силу

высокочастотного фильтра, τ_S и τ_L – временные константы для высокочастотного и низкочастотного фильтров, N_L – число низкочастотных фильтров. Знак выражения соответствует ON или OFF отклику клетки. Значения констант взяты из работы [4].

Объединяя имитацию окулярного дрифта, пространственную фильтрацию при помощи цветоразностных DoG-фильтров и временную фильтрацию, мы можем построить полную модель ганглиозной клетки P-типа. Отклик каждой клетки с координатами $\vec{x} = (x, y)$ на визуальный стимул $I = (\vec{x}, t)$ в некоторый момент времени t определяется следующей сверткой:

$$a_z(t) = \int_{S_z} \int_{-\infty}^{t} h(\overline{x}', t')I(\overline{x}', t - t')d\overline{x}dt' . \quad (5)$$

Здесь $a_z(t)$ − временной отклик клетки с рецептивным полем Z, $h(\overline{x}, t)$ − оператор ядра свертки, описывающий пространственно-временные свойства клетки.

Оператор $h(\overline{x}, t)$ можно представить в виде суммы двух операторов, представляющих центр и периферию рецептивного поля:

$$h(\overline{x}, t) = h_C(\overline{x}, t) + h_S(\overline{x}, t) = g_C(t)f_C(\overline{x}) + g_S(t)f_S(\overline{x}) . \quad (6)$$

Здесь $g_C(t)$ и $g_S(t)$ − операторы, определяющие временную фильтрацию для центра и периферии, $f_C(\overline{x})$ и $f_S(\overline{x})$ определяют пространственную фильтрацию. Предполагая $g_C(t) = g_S(t)$ как в работе [2], получаем конечную формулу:

$$h(\overline{x}, t) = g_C(t)(f_C(\overline{x}) + f_S(\overline{x})) . \quad (7)$$

Рис 4. Результат временной фильтрации и генерация спайков

Оператор $g_C(t)$ получается обратным преобразованием Фурье из формулы (4) и $f_C(\overline{x}) + f_S(\overline{x})$ представляет собой DoG – фильтр, который вычисляется обратным преобразованием Фурье из формул (2) и (3). На рис. 4

представлен результат временной фильтрации, которая применяется к одному изображению r+g- канала для самого крупного масштаба на одном шаге окулярного дрифта.

После получения результирующих изображений, сигнал переводится в спайковую форму, как показано на рис. 4. Для моделирования реалистичных паттернов спайков, в работе используется модель интегрирующих нейронов (integrate-and-fire model), как в работе [18].

Выводы

Предложена и реализована модель цветной спайковой камеры, которая имитирует работу ганглиозных клеток сетчатки человека P-типа. Модель реализует основные этапы начальной обработки визуальной информации: окулярный дрифт, пространственно-временную фильтрацию при помощи цветоразностных фильтров и генерацию спайков.

В работе реализована одна из двух задач цветового зрения – детектирование цветных краёв или перепадов яркости. Для решения второй задачи – определения цвета объектов на изображениях, требуется больше экспериментальных данных.

Модель является альтернативой использованию DVS – камеры для задач построения нейроморфных систем, которые используют спайковые нейронные сети, и может быть реализована как отдельный видео-сенсор на основе существующих цифровых камер.

Список литературы

1. Guillermo Gallego at al. Event-Based Vision: A Survey. // IEEE Transactions on Pattern Analysis and Machine Intelligence. 2022. V. 44, №. 1.

2. Таранин М.В., Таранин С.В. Пространственно-временная модель спайковой видео камеры. // XVIII Всероссийская научно-практическая конференция «Перспективные системы и задачи управления» п. Домбай, Карачаево-Черкесская республика, 2023. С. 149–155.

3. Ungsoo Samuel Kim at al. Retinal Ganglion Cells–Diversity of Cell Types and Clinical Relevance. // Frontiers in Neurology. May 2021. V.12. Article 661938

4. Ethan A. Benardete and Ehud Kaplan. Dynamics of primate P retinal ganglion cells: responses to chromatic and achromatic stimuli. // Journal of Physiology. 1999. 519.3. P. 775790.

5. Ratliff, F., & Riggs, L. A. Involuntary motions of the eye during monocular fixation. // Journal of Experimental Psychology. 1950. 40(6), 687.

6. Irina Yonit Segal at al. Decorrelation of retinal response to natural scenes by fixational eye movements. // PNAS. 2015. March 10. V.112, no.10.

7. Joseph J. Atick, A. Norman Redlich. Towards a Theory of Early Visual Processing. // Neural Computation. Massachusetts Institute of Technology. 1990. 2. 308–320.

8. Gaelle Desbordes and Michele Rucci. A model of the dynamics of retinal activity during natural visual fixation. // Visual Neuroscience. 2007. 24. P. 217–230.

9. Kuang, X., Poletti, M., Victor, J. D., & Rucci, M. Temporal encoding of spatial information during active visual fixation. // Current Biology, 2012, 22(6). 510–514.

10. Wiesel, T. N. & Hubel, D. H. Spatial and chromatic interactions in the lateral geniculate body of the rhesus monkey. // Journal of Neurophysiology. 1966. 29.

11. Hubel, D. H. Eye, Brian, and Vision. // W H Freeman & Co. 1988.

12. Field G. D., et al. Functional connectivity in the retina at the resolution of photoreceptors. // Nature. 2010. 467. P. 673–677.

13. DeValois, R. L., Abramov, I., and Jacobs, G. H. Analysis of response patternsof LGN cells. // J. Opt. Soc. Am. 1966. 56. P. 966–977.

14. Dragos Rezeanu, Maureen Neitz and Jay Neitz. How we see black and white: the role of midget ganglion cells. // Front. Neuroanat. 2022. V. 16.

15. Sara S. Patterson, Maureen Neitz and Jay Neitz. Reconciling color vision models with midget ganglion cell receptive fields. // Front. Neurosci. 2019.

16. Dragos Rezeanu, Maureen Neitz, Jay Neitz. From cones to color vision: a neurobiological model that explains the unique hues. // Journal of the Optical Society of America. 2023. № 3. V.40.

17. Lisa J. Croner, Ehud Kaplan. Receptive Fields of P and M Ganglion Cells Across the Primate Retina. // Vision Res. 1995. V.35, № 1. P. 7–24.

18. Christof Koch. Biophysics of computation. // Oxford University Press. 1999. P. 331.

Д.И. АНТОНОВ[1,2], С.В. СУХОВ[1]

[1]Ульяновский филиал
Института радиотехники и электроники им. В.А. Котельникова РАН
[2]Ульяновский государственный технический университет
d.antonov@ulireran.ru

ОБУЧЕНИЕ ИМПУЛЬСНЫХ НЕЙРОННЫХ СЕТЕЙ-КЛАССИФИКАТОРОВ С ПОМОЩЬЮ ЛОКАЛЬНЫХ ПРАВИЛ

Постоянно растущие размеры искусственных нейронных сетей и объем обучающих данных приводят ко все большим энергетическим затратам на обучение сетей. Импульсные нейронные сети (ИмНС) являются одним из перспективных кандидатов для уменьшения энергопотребления при решении задач машинного обучения. К сожалению, в импульсных нейронных сетях трудно организовать метод обратного распространения ошибки. В настоящем исследовании продемонстрирован метод обучения с подкрепле-

нием ИмНС целиком на основе локальных правил. Эксперименты проводились в среде Brian 2.0 на общедоступных наборах данных.

Ключевые слова: *искусственная нейронная сеть, импульсная нейронная сеть, обучение с подкреплением, пластичность зависящая от времени спайка.*

Введение

За последнее десятилетие методы машинного обучения добились значительного прогресса и стали широко распространёнными инструментами для решения задач обнаружения и классификации объектов, распознавания речи и других. Процесс обучения искусственных нейронных сетей (ИНС) при этом является хорошо отлаженной процедурой и основан на методе обратного распространения ошибки. К сожалению, в связи с увеличением размеров ИНС и размеров обучающих данных процесс обучения ИНС стал требовать огромных энергетических ресурсов.

Импульсные нейронные сети (ИмНС) являются новым поколением ИНС [1], обещая намного лучшую энергоэффективность и внутреннюю поддержку динамических процессов. В будущем ИмНС могут служить основой для организации вычислительного процесса на перспективном нейроморфном оборудовании [2]. Концепция ИмНС вдохновлена биологическими нейронными сетями, обладающими способностью эффективно обрабатывать дискретные пространственно-временные сигналы (импульсы, спайки). ИмНС состоят из нейронов, которые интегрируют входные сигналы и генерируют выходной импульс при достижении определенного порога. Отдельные нейроны в ИмНС связаны с помощью синапсов (аналогов весов в ИНС). Сила синапсов определяет величину сигнала, переходящего от пресинаптического нейрона к постсинаптическому. Как и в аналоговых нейронных сетях, обучение ИмНС заключается в контролируемом изменении величины синаптических связей.

Для обучения ИмНС можно придумать суррогатные методы, имитирующие обратное распространение ошибки (например, в [3], [4], [5]). Однако модель нейроморфных вычислений предполагает обучение, реализованное локально для каждого из синапсов. Для этих целей используется пластичность зависящая от времени спайка (spike-time dependent plasticity, STDP) [6], [7]. В данной модели обучения сила синапса между пре- и пост-синаптическим нейроном корректируется в зависимости от относительного времени спайков, сгенерированных этими нейронами. Методы STDP идеально подходят для обучения без учителя. В частности, известно, что STDP приводит к выделению главных компонент в структуре обучающих данных [8].

Использование локального обучающего правила очень привлекательно и для практических применений ИмНС, поскольку оно позволяет эффективное использование на перспективном нейроморфном оборудовании. В то же время остается вопрос о применимости локальных методов обучения в задачах обучения с учителем (задачах классификации).

В нашей работе решена задача классификации при обучении ИмНС без обратного распространения ошибки только на основе локальных правил. Обучение с учителем при этом заменено на обучение с подкреплением. В отличие от предыдущих работ [9, 10, 11], мы реализовали механизм STDP с подкреплением в динамических ИмНС.

Постановка задачи и описание алгоритма

В нашем исследовании мы предполагаем создать импульсную нейронную сеть-классификатор. Обучение нейронной сети будет проводиться на наборе изображений.

Brian 2.0 [12] – среда моделирования импульсных (спайковых) нейронных сетей с открытым исходным кодом. Среда создана на языке программирования Python и доступна практически на всех платформах. Brian 2.0 позволяет прямо задавать свойства различных групп нейронов и синапсов.

ИмНС, обучающаяся по принципам STDP с подкреплением (reward-modulated spike-time dependent plasticity, R-STDP), была реализована в среде Brain 2.0.

Как и в случае ИНС, импульсная сеть состоит из последовательности слоев. В отличие от метода обратного распространения ошибки, где обучение происходит глобально для всей сети, обучение ИмНС производится послойно (локально). Ранее, в работах [13] и [14] обучение подобных сетей проводилось на основе метода STDP. Новизна нашей работы состоит в реализации локального обучения синаптических связей на основе R-STDP.

Обучение сети происходит на последовательности изображений по следующему алгоритму R-STDP:

- каждое изображение, загружаемое на вход сети, порождает в нейронах первого (пуассоновского) слоя последовательность пуассоновских импульсов, которые, проходя через синапсы, влияют на их веса согласно правилу STDP;
- постсинаптические возбуждающие нейроны второго слоя при накоплении потенциала генерируют импульсы (спайки) в тот момент, когда мембранный потенциал нейрона превышает пороговое значение; при этом индекс постсинаптического нейрона, сгенерировавшего наибольшее

количество спайков (нейрон-«победитель»), является указателем на класс, к которому сеть относит данное изображение;

- последующие действия непосредственно связаны с правилом R-STDP и заключаются в том, что результат проведённой классификации используется для обновления весов группы синапсов, соединяющих нейроны первого слоя и возбуждающие нейроны второго слоя (далее – синапсы группы S_1). Величина изменения веса определяется вознаграждением (reward) или наказанием (punishment), решение о котором принимается на основе правильности результата классификации. Возбуждающий нейрон, сгенерировавший наибольшее количество спайков, определяет решение сети. В случае соответствия результата классификации истинному классу данных (target label) принимается решение о вознаграждении и веса синапсов группы S_1, находящихся между пуассоновским слоем и возбуждающим нейроном-«победителем» второго слоя изменяются на величину:

$$\Delta w_{ij} = k_{rew} \cdot median(w_{ij}), \quad (1)$$

где j − индекс одного возбуждающего нейрона-«победителя», индекс i соответствует нейронам пуассоновского слоя и пробегает значения от 0 до 783 (в слое содержится 784 пуассоновских нейрона), коэффициент вознаграждения $k_{rew} > 0$, медиана вычисляется по весам синаптических связей, соединяющих нейрон-«победитель» с нейронами пуассоновского слоя. Аналогично, если результат классификации не соответствует истинному классу, то принимается решение о наказании и те же синаптические веса изменяются на величину:

$$\Delta w_{ij} = k_{pun} \cdot median(w_{ij}), \quad (2)$$

где, в отличие от случая с вознаграждением, коэффициент наказания $k_{pun} < 0$;

- в результате описанного воздействия на сеть вес связей, которые будут проводить «правильные» сигналы, будет расти, а у остальных - уменьшаться. В данной ситуации есть вероятность попадания в ловушку локальных оптимумов и, во избежание подобного нежелательного развития событий, требуется применение дополнительных мер. Начальные синаптические веса между пуассоновским слоем и возбуждающими нейронами второго слоя задаются случайным образом, что предопределяет сравнительно бóльшую долю ошибочно классифицированных данных в начале обучения, которая должна уменьшаться по мере обучения. При большой доле ошибочной классификации частые наказания ведут к быстрому ослаблению весов и формированию неработающих связей. Аналогичная ситуация возникает при большой доле правильно классифицированных данных, что может привести к существенному относительному увеличению весов. Для балансировки влияния вознаграждений и наказаний в процессе обучения сети

выполняется корреляция весов за счёт умножения изменения веса на относительное значение правильной и ошибочной классификации так, как это было сделано в [11]:

$$w_{ij} = w_{ij} + \begin{cases} {N_{miss}}/{N} \cdot \Delta w_{ij}, \text{в случае вознаграждения;} \\ {N_{hit}}/{N} \cdot \Delta w_{ij}, \text{в иных случаях,} \end{cases} \quad (3)$$

где N – количество элементов тренировочной выборки, уже прошедших через сеть, из них N_{miss} и N_{hit} – количество элементов, классифицированных, соответственно, ошибочно и правильно.

Дополнительно на значение изменяющихся синаптических весов накладывается условие:

$$0 \leq w_{ij} \leq w_{max}, \quad (4)$$

где w_{max} – верхняя граница весов.

Ниже приведён псевдокод описанного алгоритма R-STDP (алгоритм 1).

Алгоритм 1. Алгоритм R-STDP обучения динамической ИмНС

Input: $Images, Labels,\ E_{rest}, E_{exc}, E_{inh}, V_{reset}, V_{thres}, g_e, g_i, \tau_e, \tau_i, epochs$
Output: обученная ИмНС с оптимизированными весами w_{ij} группы S_1

```
процесс обучения ИмНС
for epochs steps
    accurate = 0
    for sample in Images
        нейроны 1-го слоя генерируют последовательности импульсов
        импульсы, проходя синапсы группы S1, изменяют их веса wij
        возбуждающие нейроны 2-го слоя генерируют импульсы
        нейрон, генерирующий наиболее часто, - «победитель»
        index_win = индекс нейрона-«победителя» j
        group of index_win = index_win // 10
        if group of index_win == Labels(sample):
            изменить веса wij группы S1 согласно (1), (3), (4)
            accurate += 1
        else:
            изменить веса wij группы S1 согласно (2), (3), (4)
    end for
    accurate = accurate / length (Images)
end for
```

Импульсная нейронная сеть

В данном разделе представлена архитектура и принцип работы ИмНС, использованной в наших исследованиях. Архитектура данной сети построена на базе архитектуры, предложенной в работе [13] и позднее переработанной Д. Ларионовым и Д. Ивановым в [14]. Она состоит из двух слоев: первый входной слой содержит 784 нейронов (по одному нейрону на каждый пиксель изображения размером 28 × 28 пикселей), второй слой состоит из 100 возбуждающих и 100 тормозящих нейронов. Связь между возбуждающими и тормозящими нейронами, описанная ниже, позволяет наиболее активным возбуждающим нейронам снижать активность своих соседей, тем самым осуществляя латеральное торможение. Латеральное торможение препятствует распространению сигнала от наиболее возбуждённых нейронов к соседним нейронам в латеральном направлении (иначе говоря – в боковом направлении), что позволяет усилить градиент потенциала возбуждающих нейронов слоя в каждый момент времени.

Рис.1. Архитектура нейронной сети; количество нейронов в слоях показано условно: первый слой содержит 784 пуассоновских нейрона, второй – 100 возбуждающих и 100 тормозящих нейронов; S_1, S_2 и S_3 − синаптические связи, показанные на примере связей, идущих от 1 пуассоновского нейрона

Работа сети с архитектурой, изображённой на рис. 1, заключается в циклическом выполнении следующих шагов:

1) на вход сети подаётся изображение размером 28 × 28 пикселей, каждый пиксель которого попадает на соответствующий нейрон пуассонов-

ского слоя, состоящего из 784 нейронов (по числу пикселей). Каждый пиксель изображения вызывает генерацию нейроном пуассоновского слоя последовательности импульсов со средней частотой, равной интенсивности данного пикселя, т.е. происходит частотное кодирование данных;

2) из нейронов пуассоновского слоя сигнал по синапсам попадает в возбуждающие нейроны второго слоя (100 возбуждающих нейронов), синапсы группы S_1 связывают пуассоновские нейроны с возбуждающими нейронами по принципу «один-ко-всем»; группа синапсов S_1 ответственна за обучение сети по правилу R-STDP, которое определяет процесс изменения синаптических весов;

3) поступление импульсов в возбуждающие нейроны ведёт к росту нейронного мембранного потенциала V, который при достижении порога V_{thres} порождает импульс, передающийся по синапсам группы S_2 в тормозящие нейроны второго слоя (100 тормозящих нейронов); каждый импульс, вышедший из возбуждающего нейрона, будет запускать импульс в соответствующем ему тормозящем нейроне, так как синапсы группы S_2 связывают их по принципу «один-к-одному»; веса группы синапсов S_2 остаются постоянными;

4) от тормозящих нейронов сигнал идёт назад к возбуждающим нейронам по принципу «один-ко-всем-кроме-инициирующего» по группе синапсов S_3; веса группы синапсов S_3 также остаются постоянными; такая связь обеспечивает латеральное торможение.

Изображения MNIST показываются сети последовательно по одному. После демонстрации сети одного изображения на протяжении 350 мс, на 150 мс запускается период покоя при отсутствии сигнала на входных нейронах. В течение периода покоя потенциал возбуждающих нейронов падает до нижнего порога, после чего цикл повторяется на следующей порции данных.

Для нейронов используется модель интегрирующих нейронов с утечкой (leaky integrate-and-fire model). Работа данной модели происходит таким образом, что синапсы увеличивают свою проводимость в момент прихода пресинаптического импульса перед генерацией постсинаптического импульса, если же этого не происходит, то проводимость синапса затухает экспоненциально.

В использованной нами модели, согласно [13] и [14], мембранный потенциал нейрона V описывается уравнением:

$$\tau \frac{dV}{dt} = (E_{rest} - V) + g_e(E_{exc} - V) + g_i(E_{inh} - V), \qquad (5)$$

где τ – характерное время релаксации мембранного потенциала, E_{rest} – мембранный потенциал покоя, E_{exc} и E_{inh} – равновесные потенциалы воз-

буждающих и тормозящих синапсов, g_e и g_i – проводимости возбуждающих и тормозящих синапсов. Генерация импульса (спайка) происходит в нейроне в тот момент, когда суммарный нейронный мембранный потенциал V превышает некоторый пороговый потенциал V_{thres}. Генерация спайка сопровождается падением мембранного потенциала до значения V_{reset}, после чего нейрон теряет способность генерации спайка в течение так называемого рефракторного периода (refractory period).

Динамика поведения синапса определяется уравнениями:

$$\tau_e \frac{dg_e}{dt} = -g_e \text{ и } \tau_i \frac{dg_i}{dt} = -g_i, \quad (6)$$

где g_e и g_i – проводимость синапса для возбуждающего и тормозящего нейрона, соответственно, τ_e и τ_i – соответствующие временны́е константы. При попадании в синапс пресинаптического спайка проводимость синапса вырастает моментально, после чего спадает экспоненциально согласно уравнениям (6). Как указывается в работе [13], для работы нейронной сети важна сбалансированность между тормозной и возбуждающей синаптическими проводимостями, чтобы, с одной стороны, латеральное торможение не было слишком слабым, и, с другой стороны, чтобы выбор победителя не подавлял полностью срабатывания других нейронов.

Условия проведения экспериментов

Эксперименты проводятся на ИмНС, построенной на основе архитектуры, предложенной в работах [13] и [14].

Обучение нейронной сети в нашей работе, равно как в работах [13] и [14], производится на изображениях рукописных цифр MNIST, в тренировочном наборе которого содержится 60000 изображений. Каждое изображение состоит из 784 (28 × 28) пикселей различной интенсивности (от 0 до 255). Как и в работах [13] и [14] для целей снижения максимальной частоты импульсов, получаемых при частотном кодировании изображений в сети, до 63,75 Гц, интенсивность изображений в наборе перед вводом в сеть делится на 4. Вместе с тем, разработанная сеть имеет существенное отличие, заключающееся в использовании правила R-STDP, что выражается в следующем.

Авторы [13] определяли класс возбуждающих нейронов после завершения обучения по значению максимального отклика на подачу всех классов данных за одно представление обучающего набора, для чего использовались метки класса. Определив таким способом принадлежность нейрона к одному из классов, по которым происходит классификация, они использовали эти знания для классификации данных из тестового набора MNIST.

Точность классификации при тесте определялась как среднее по всем ответам каждого нейрона по принадлежности тестируемых данных к классам и последующего выбора класса с самой высокой средней частотой срабатывания.

Авторы программного кода [14] проводили классификацию, тоже используя запись реакции возбуждающих нейронов на входящие изображения, но не на основе усреднения их отклика, а вынося процесс классификации вовне ИмНС. Для этого они пользовались классификатором Случайного леса (Random Forest Classifier), который обучали с учителем на основе полученных откликов от возбуждающих нейронов с использованием меток классов. Обученный таким образом классификатор Случайного леса использовался в дальнейшем для проведения классификации тестового набора MNIST.

В нашем случае классификация основана на локальном обучении синапсов группы S_1, расположенных между пуассоновскими нейронами и возбуждающими нейронами второго слоя, по правилу R-STDP. Применение данного правила должно направлять процесс изменения синаптических весов группы S_1 во время обучения таким образом, чтобы при прохождении последовательностей импульсов инициировать срабатывание групп возбуждающих нейронов, соответствующих определённому классу.

Происходит этот процесс следующим образом: 100 возбуждающих нейронов второго слоя разделены на 10 классов по 10 нейронов в каждом по числу классов изображений (набор MNIST представляет собой изображения 10 цифр). При подсчёте частоты генерации импульсов выявляется индекс нейрона-«победителя», при этом если данный индекс находится в промежутке от 0 до 9, то изображению присваивается класс «0», если от 10 до 19 – класс «1» и так далее.

В результате производимого обучения с подкреплением проводимости синапсов, которые обеспечивают «правильную» работу нейронов, увеличиваются, а проводимости остальных уменьшаются.

Классификация тестового набора выполняется аналогично на основе сравнения частоты срабатывания возбуждающих нейронов обученной сети: в качестве классифицирующей также выступает группа с максимально большой частотой срабатывания нейронов.

Выводы

Нами предложена архитектура динамической импульсной сети-классификатора, реализованная в среде Brian 2.0. Разработанный алгоритм обучения ИмНС основан на локальных методах обучения R-STDP.

Локальный метод обучения с подкреплением позволяет обойти трудности, связанные с применением метода обратного распространения ошибки в импульсных нейронных сетях.

Список литературы

1. Maass W. Networks of spiking neurons: The third generation of neural network models // Neural Networks. 1997. V. 10. No 9. P. 1659–1671.
2. Roy K., Jaiswal A., Panda P. Towards spike-based machine intelligence with neuromorphic computing // Nature. 2019. V. 575. No 7784. P. 607–617.
3. Lee J.H., Delbruck T., Pfeiffer M. Training Deep Spiking Neural Networks Using Backpropagation // Frontiers in Neuroscience. 2016. V.10. P. 1–13.
4. Tavanaei A., Maida A. BP-STDP: Approximating backpropagation using spike timing dependent plasticity // Neurocomputing. 2019. V.330. P. 39–47.
5. Kheradpisheh S. R., Masquelier T. Temporal backpropagation for spiking neural networks with one spike per neuron // International Journal of Neural Systems. 2020. V.30. No 6. P. 1–16.
6. Caporale N., Dan Y. Spike Timing–Dependent Plasticity: A Hebbian Learning Rule // Annual Review of Neuroscience. 2008.V. 31. No 1. P. 25–46.
7. Tavanaei A., Ghodrati M., Kheradpisheh S.R., Masquelier T., Maida A.S. Deep learning in spiking neural networks // Neural Networks. 2019. V. 111. P. 47–63.
8. Enríquez-Gaytán J., Gomez-Castaneda F., Flores-Nava L.M., Moreno J. Spiking neural network approaches PCA with metaheuristics // Electronics Letters. 2020. V.56. No 10. P. 488–490.
9. Masquelier T., Thorpe S.J. Unsupervised Learning of Visual Features through Spike Timing Dependent Plasticity // PLOS Computational Biology. 2007. V.3. No 2. P. 0247–0257.
10. Kheradpisheh S.R., Ganjtabesh M., Thorpe S.J., Masquelier T. STDP-based spiking deep convolutional neural networks for object recognition // Neural Networks. 2017. V.99. P. 56–67.
11. Mozafari M., Kheradpisheh S.R., Masquelier T., Nowzari-Dalini A., Ganjtabesh M. First-spike-based visual categorization using reward-modulated STDP // IEEE Transactions on Neural Networks and Learning Systems. 2018. V.29. No 12. P. 6178-6190.
12. https://briansimulator.org/posts/brian-2-0/
13. Diehl P., Cook M. Unsupervised learning of digit recognition using spike-timing-dependent plasticity // Frontiers in Computational Neuroscience. 2015. V.9. P. 1–9.
14. https://www.kaggle.com/code/dlarionov/mnist-spiking-neural-network/notebook

Секция

Нейробиология

И.Е. МЫСИН
Институт теоретической и экспериментальной биофизики РАН, Пущино
imysin@mail.ru

АДАПТАЦИЯ МЕТОДОЛОГИИ МАШИННОГО ОБУЧЕНИЯ ДЛЯ МОДЕЛИРОВАНИЯ НЕЙРОННЫХ СЕТЕЙ МОЗГА[1]

Нейронаука накопила большой объем данных о функционировании мозга при обработке информации. Однако обобщить объем современных данных в виде математических моделей не удалось. Мы предлагаем новый подход построению моделей импульсных нейронных сетей. Наш подход основан на объединении двух уже известных подходов: популяционных моделях и автоматическом дифференцировании. Показано, что с помощью градиентного спуска можно находить параметры сети, наилучшим образом описывающие экспериментальные данные.

Ключевые слова: *популяционные модели нейронов, поле CA1 гиппокампа, интернейроны, кратковременная синаптическая пластичность, TensorFlow.*

Введение

В 2013 г. стартовал проект Human Brain Project (HBP). В рамках этого проекта авторы обещали разработать новую интегрированную стратегию для понимания человеческого мозга и новую исследовательскую платформу, которая объединила бы все данные и знания, которые мы можем получить о структуре и функциях мозга. Авторы проекта ставили целью создать первую в мире модель мозга человека и грызунов [1]. Проект HBP является беспрецедентным по своим масштабам и крупнейшим в истории изучения человеческого мозга, бюджет проекта составляет 1,6 млрд.$. В этом году проект заканчивается. Этот проект существенно продвинул наше

[1] Данная работа выполнена при поддержке РНФ, проект № 20-71-10109.

понимание работы мозга. Однако авторы HBP не достигли заявленных целей по моделированию мозга человека, несмотря на колоссальные ресурсы. Это свидетельствует о кризисе в теоретической нейронауке. Не существует общепринятой методологии построения моделей нейронных сетей мозга. Опыт HBP показывает, что большого количества экспериментальных данных недостаточно для построения точной модели мозга.

Мы предлагаем адаптировать методологию машинного обучения для моделирования сетей, имитирующих работу мозга. Ключевое звено в нашем подходе − это сведение процесса моделирования к решению задачи оптимизации. Мы подробно рассмотрим плюсы и минусы нашего подхода.

Трудности моделирования мозга

Математическое описание сложных экспериментальных явлений требует большого количества уравнений. Чем больше уравнений, тем больше требуется известных параметров. Уравнения для описания нейронов и синапсов известны. Однако нахождение параметров − это трудная задача.

Существует два методологических подхода к решению проблемы параметров. Последователи первого подхода, по сути, отказываются от преодоления проблемы параметров. Они предлагают простые модели отдельных экспериментальных явлений. В простых моделях мало параметров. Динамика модели прозрачна. Свободные параметры могут быть настроены исходя из логики работы модели. Большинство верифицированных экспериментальных явлений имеют простые модели, объясняющие их. Главная трудность этого подхода состоит в невозможности увеличения сложности модели. Это делает не позволяет интегрировать простые модели в более сложные, описывающие уже многие экспериментальные явления.

Последователи второго подхода пытаются преодолевать проблему параметров с помощью экспериментальных измерений. Этим путем шли авторы HBP. Существуют и другие аналогичные менее масштабные проекты, например Hipposampome (Hipposampome.org). Однако авторы таких проектов не представили прорывных теоретических результатов о функционировании нейронных сетей мозга. Мы полагаем, что причина состоит в том, что наличие большой базы экспериментальных данных о параметрах нейронов и синапсов недостаточное условие для воспроизведения экспериментальных явлений сетевой динамики. Существует две причины, объясняющие недостаточность наличия баз данных для моделирования. Во-первых, многие нейросетевые модели проявляют хаотические свойства [2]. Точности экспериментальных измерений недостаточно корректного функ-

ционирования модели. Во-вторых, при моделировании сложных экспериментальных явлений сложно понять, что учитывать в модели и какие элементы включать в неё. Иными словами, можно подставить в корректные параметры в уравнения, но мощности самих уравнений может не хватить для описания эмпирических закономерностей. С биологической точки зрения эта проблема заключается в том, что модель может не учитывать какие-то важные элементы или учитывать их недостаточно детально. В то же время слишком детальное моделирование невозможно по причине ограниченности вычислительных ресурсов.

Мы полагаем, что перечисленные трудности в совокупности составляют барьер на пути развития теоретической нейронауки.

Пример построения модели

В дальнейшем описании мы будем ссылаться на нашу модель в качестве примера [3]. В этой работе мы моделировали динамику разрядов нейронов поля CA1 гиппокампа в ходе генерации тета-ритма. В этом разделе мы кратко изложим суть работы.

Тета-ритм (4–12 Гц) − это главный электрографический ритм гиппокампа, без тета-ритма невозможно формирование памяти. В поле CA1 гиппокампа выделяют до 20 классов тормозных нейронов (интернейронов). Нейроны каждой популяции преимущественно разряжаются на своей фазе тета-ритма [4]. Основная проблема при построении модели распределения нейронов по фазам тета-ритма − это выявление механизма стабилизации антагонистических отношений между разными популяциями интернейронов. Например, PV и CCK корзинчатые нейроны тормозят друг друга и разряжаются на противоположных фазах тета-ритма [4]. Существует небольшой диапазон параметров связей и входов на эти нейроны, когда они формируют устойчивую противофазную активность. В большом числе случаев одна из популяций полностью подавляет вторую.

Мы предположили, что кратковременная синаптическая депрессия осуществляет стабилизацию структуры активности интернейронов. Если нейроны первой популяции разряжаются очень долго, их синапсы депрессируются. Это дает возможность второй популяции выйти из-под тормозного влияния и начать разряжаться. Эту гипотезу мы проверили с помощью описанного ниже подхода. Мы моделировали взаимодействие семи основных тормозных популяций: PV и CCK корзинчатые, аксо-аксональные, OLM, Ivy, дендритные и нейроглиаформные нейроны. Эти нейроны получали модулированные возбуждающие входы от популяций пирамидных

нейронов полей CA3 и CA1 и энторинальной коры. Частота разрядов возбуждающих входов задавалась согласно экспериментальным данным, а не симулировалась в модели, однако параметры синапсов от возбуждающих входов также оптимизировались. Схема связей была взята из публикаций проекта Hipposampome.org [5]. Синапсы описывались моделью Тсодыкса-Маркрама [5]. Всего модели было 49 связей между популяциями. Модель синапса содержит 6 параметров: плотность связей, синаптическая проводимость, доля синаптических везикул, выбрасывающихся при одном акте синаптической передачи, а также 3 параметра, описывающих характерные времена переходов нейромедиатора между активным и неактивным пулом. У каждой популяции нейронов настраивался параметр постоянного тока, имитирующий медленное действие модуляторов. Всего в нашей симуляции оптимизировался 301 параметр. Мы использовали оптимизатор Adam и пакет Tensorflow.

Фундаментальная биологическая значимость модели и математический аппарат изложены в статье [3]. Эта статья будет посвящена методологическому аспекту моделирования. Мы обсудим его преимущества и недостатки.

Предлагаемая методология построения нейросетевых моделей

Мы предлагаем преодолевать проблему параметров путем сведения процесса построения модели к решению задачи оптимизации. Иными словами, предлагается находить оптимальные параметры модели, чтобы она описывала наилучшим образом, описывала экспериментальные данные. Мы рассматриваем модели сетей, это подразумевает, что требуется настройка большого числа параметров до нескольких сотен. Требование к возможности настройки большого числа параметров делает невозможным применение методов оптимизации нулевого порядка.

Оценка градиента возможна с помощью применения пакетов автоматического дифференцирования (Tensorflow, Torch) или с помощью метода сопряженного состояния [6]. В нескольких публикациях уже использовалась оптимизация с помощью градиентного спуска для поиска параметров модели [7, 8]. Однако авторы этих работ преследовали цель поиска новой архитектуры для анализа данных, а не для создания моделей сетей мозга.

Активность нейронов реального мозга зашумлена. Подавляющее большинство экспериментальных явлений получены в результате усреднения активности одного или нескольких нейронов в зависимости от внешних стимулов или внутреннего состояния. Иными словами, экспериментальные феномены нейросетевой динамики − это эмпирические распределения. В

этом контексте моделирование заключается в описании параметров распределений. Однако это представляет трудность в контексте предыдущего тезиса о необходимости использования методов градиентного спуска.

Мы предлагаем преодолевать эту трудность с помощью применения популяционных моделей. В такого типа моделях воспроизводится поведение не одного нейрона, а частота разрядов большой популяции нейронов. Наиболее известен популяционный подход на основе уравнения Фоккера-Планка, позволяющий описать частоту разрядов бесконечно большой популяции однородных пороговых интеграторов (LIF), получающих индивидуальный шум [9]. В нашей работе мы использовали метод моделирования распределения рефрактерной плотности (РПП) [10, 11]. Данный метод также рассматривает бесконечно большую популяцию однородных нейронов, получающих индивидуальный шум, однако в отличие от метода на основе уравнения Фоккера-Планка, позволяет моделировать популяции нейронов типа Ходжкина-Хаксли. Как и в случае моделей отдельных нейронов, популяционный подход позволяет соединять элементы и моделировать нейронные сети. Результаты симуляций с помощью популяционных подходов можно напрямую соотносить с экспериментальными данными. Часто можно ввести аппроксимацию наблюдаемой вероятность разрядов нейронов. Это дает возможность составить функцию ошибки и решать задачу оптимизации, т.е. нахождения параметров модели, наилучшим образом описывающих экспериментальные данные.

В пункте 2 мы сформулировали аппроксимации экспериментальных данных о вероятности разрядов нейронов. Аппроксимации как правило включают параметры, которые могут значительно варьироваться. Например, частота тета-ритма может изменяться от 4 до 12 Гц у одного животного в зависимости от когнитивных задач. Мы можем использовать подобные переменные для тестирования модели аналогично перекрестной проверке, применяемой в машинном обучении. Можно оптимизировать при одних параметрах, а проводить тестирование при других. Сохранение воспроизводимости эмпирических распределений будет говорить о правильности моделей. В нашем случае мы оптимизировали модель при частоте тета-ритма 7 Гц. При входах с другими частотами в диапазоне тета-ритма форма распределений активности нейронов по фазе тета-ритма сохранялась.

Если модель результаты оптимизации удовлетворительны (пункт 5) и модель проходит тестирование (пункт 6), то гипотеза подтверждена. Если оптимизировать модель не удалось, то необходимо дополнить модель новыми элементами и вернуться на этап 3.

Этот подход аналогичен методологии построения моделей машинного обучения для анализа данных. Можно рассматривать модель как однослойную рекуррентную сеть, обучающуюся воспроизводить последовательность векторов (частоты импульсов нейронных популяций модели) по входной последовательности (частоты импульсов входных популяций). В машинном обучении для рекуррентных сетей используются модели LSTM и GRU. В нашем случае общий подход аналогичен, но вместо элементов сети используются уравнения в частных производных для описания вероятности разрядов нейронов.

Преимущества нашего подхода:

1) Автоматизация проверки гипотез об функционировании сложных нейронных систем.

В нашем случае сеть содержала сеть нейронных популяций. Динамика такой сети нетривиальна. Однако с помощью оптимизации мы исследовали связь кратковременной пластичности и механизмов генерации тета-ритма.

2) Возможность находить нетривиальные режимы работы нейронных сетей − это очень важное свойство теоретических исследований. Оптимизированные параметры можно исследовать и делать теоретические прогнозы.

3) Использование развитой инфраструктуры машинного обучения, включая программные пакеты, алгоритмы оптимизации и вычислительные мощности, заточенные под задачи машинного обучения.

Недостатки нашего подхода:

1) Ограничения, накладываемые популяционными моделями.

Метод популяционного моделирования на основе уравнений Фоккера-Планка позволяет описывать модели нейронов только с одной или двумя динамическими переменными. Модель РРП может быть использована для моделей нейронов типа Ходжкина-Хаксли, однако и она теряет мощность при увеличении числа динамических переменных в модели нейронов.

2) Требуются значительные вычислительные ресурсы, в частности память. Модель сети должна пересчитываться много итераций. Автоматическое дифференцирование требует много памяти для сохранения промежуточных результатов вычислений, которые в дальнейшем будут использованы для вычисления градиентов. Поэтому в реальных задачах число оптимизируемых параметров сети ограничивается несколькими сотнями.

3) Требуются достаточный объем экспериментальных данных для введения обоснованных аппроксимаций.

Выводы

Алгоритмы машинного обучения показывают выдающиеся результаты в области создания искусственного интеллекта. Суть многих алгоритмов сводится к решению задачи оптимизации. Мы предлагаем адаптировать этот подход к задачам теоретической нейронауки. Вместе с возможностью оптимизации параметров нейросетевых моделей возможно адаптировать другие методические подходы машинного обучения.

Наш подход не отрицает необходимость сбора баз экспериментальных данных. Оптимизация моделей может хорошо дополнить процессы сбора данных. Развитие математического аппарата моделей может стать одной из причин прорыва в построении крупномасштабных моделей мозга.

Список литературы

1. Markram H. et al. Introducing the Human Brain Project // Procedia Comput. Sci. 2011. Vol. 7. P. 39–42.

2. Korn H., Faure P. Is there chaos in the brain? II. Experimental evidence and related models // C. R. Biol. 2003. Vol. 326, № 9. P. 787–840.

3. Mysin I. Phase relations of interneuronal activity relative to theta rhythm // Frontiers in Neural Circuits. 2023. Vol. 17.

4. Somogyi P. et al. Temporal redistribution of inhibition over neuronal subcellular domains underlies state-dependent rhythmic change of excitability in the hippocampus // Phil Trans R Soc B. 2014. Vol. 369, № 1635. P. 20120518.

5. Moradi K. et al. Normalized unitary synaptic signaling of the hippocampus and entorhinal cortex predicted by deep learning of experimental recordings: 1 // Commun. Biol. Nature Publishing Group, 2022. Vol. 5, № 1. P. 1–19.

6. Chen R.T.Q. et al. Neural Ordinary Differential Equations // ArXiv180607366 Cs Stat. 2019.

7. Lee J.H., Haghighatshoar S., Karbasi A. Exact Gradient Computation for Spiking Neural Networks Through Forward Propagation: arXiv:2210.15415. arXiv, 2023.

8. Fontanini R., Esseni D., Loghi M. Reducing the Spike Rate in Deep Spiking Neural Networks // Proceedings of the International Conference on Neuromorphic Systems 2022. Knoxville TN USA: ACM, 2022. P. 1–8.

9. Brunel N. Dynamics of sparsely connected networks of excitatory and inhibitory spiking neurons // J. Comput. Neurosci. 2000. Vol. 8, № 3. P. 183–208.

10. Chizhov A.V., Graham L.J. Efficient evaluation of neuron populations receiving colored-noise current based on a refractory density method // Phys. Rev. E. 2008. Vol. 77, № 1.

11. Chizhov A.V., Rodrigues S., Terry J.R. A comparative analysis of a firing-rate model and a conductance-based neural population model // Phys. Lett. A. 2007. Vol. 369, № 1. P. 31–36.

Н.Г. БИБИКОВ
АО Акустический институт им. академика Н.Н. Андреева,
Институт проблем передачи информации им. А.А Харкевича РАН
nbibikov1@yandex.ru

НЕЙРОНЫ СЛУХОВОЙ КОРЫ НЕНАРКОТИЗИРОВАННОЙ КОШКИ ВОСПРОИЗВОДЯТ БЫСТРЫЕ ИЗМЕНЕНИЯ ДЛИТЕЛЬНЫХ СИГНАЛОВ

Реакции одиночных нейронов слуховой коры кошки на разнообразные сложные сигналы (тоны, модулированные шумом в полосе 0-50 Гц, вокальные и речевые сигналы, звуки потенциальных жертв) исследовались в условиях, приближенных к естественным (отсутствие анестезии, отсутствие звукозаглушения). В отличии от данных, получаемых при любых видах наркоза, нейроны коры были способны к длительной реакции на подобные сигналы. При этом в течение всего воздействия сохранялась способность к воспроизведению быстрых временных изменений амплитуды.

Ключевые слова: *слуховая кора, кошка, отсутствие наркоза, отсутствие габитуации, временное кодирование*.

Введение

Слуховая кора кошки в течение многих лет была излюбленным объектом исследователей кодирования сенсорной информации в специализированных корковых зонах. При этом после начальных работ, выполненных такими корифеями электрофизиологии как Хьюбел [1], многие последующие исследователи осуществляли свои эксперименты на животных, находящихся под действием разнообразных наркотических веществ, прежде всего нембутала и хлоралозы. В результате сложилось мнение о том, что реакции нейронов слуховой коры по сравнению с нижележащими уровнями слуховой системы отличаются выраженным ослаблением ответа во времени, габитуацией последовательных реакций и неспособностью воспроизводить быстрые изменения амплитуды [2]. Данные, полученные при кетаминовом наркозе, характеризуются появлением спонтанной активности и несколько более высокой лабильностью ответов [3]. При этом, однако, следует учитывать известный факт торможения кетамином NMDA рецепторов нервных клеток.

В последние годы стало совершенно очевидно, что все наркотические вещества приводят к существенному искажению активности нейронов слуховой коры. При работе с такими объектами как грызуны [4] и приматы [5] результаты вновь были получены при полном отсутствии фармакологических воздействий. При этом выяснилось, что способность клеток коры воспроизводить быстрые изменения амплитуды резко возрастает в условиях отсутствия наркоза. Совсем недавно этот же результат был подтверждён при регистрации нейронной активности первичной зоны слуховой коры бодрствующей кошки [6].

В указанной работе, как и во многих других исследованиях, изучались реакции нейронов коры на сравнительно короткие, чаще всего тональные отрезки сигнала. Между тем в естественной жизни животное обычно находится в активном звуковом окружении. Учитывая такую ситуацию, начиная с 2019 года, по инициативе Ивана Николаевича Пигарева мы исследовали поведение нейронов слуховой коры кошки, находящейся в бодрствовании, дремоте и разных стадиях сна при действии сложных широкополосных сигналов сравнительно высокого уровня. Некоторые полученные данные были опубликованы [7, 8, 9]. В настоящей работе мы подробно рассмотрим ответ клетки первичной слуховой коры на тональный сигнал характеристической частоты, модулированный по амплитуде низкочастотным шумом. Заметим, что после узкополосной фильтрации на улитке, любые звуки перекодируются в сигналы подобного типа.

Методика

Методика подготовки животного к проведению экспериментов и проведения самого эксперимента подробно описана Иван Николаевичем Пигаревым в предыдущих публикациях [10, 11]. Методические аспекты, касающиеся звуковой стимуляции, были дополнительно обсуждены в работе [8].

Работа выполнялась на взрослой беспородной кошке в возрасте 4 лет. После довольно длительной (полумесячной) тренировки с пищевым подкреплением животное привыкло находиться в установке, где у неё была фиксирована только голова, и в процессе эксперимента она не проявляла выраженного беспокойства. Этическая сторона проекта была согласована с комиссией Института проблем передачи информации.

Регистрация нейронной активности была дифференциальной от двух электродов с диаметром кончика порядка 10 мкМ, расположенных на расстоянии 400–500 мкМ друг от друга. В процессе эксперимента эта активность регистрировалась в широком диапазоне частот.

В последующем биоактивность отфильтровывалась в полосе 0.3–5.0 кГц и обрабатывалась программой Spike 2 с целью выделения потенциалов действия одиночных клеток. В ряде случаев спайки одной клетки, амплитуда которых существенно превосходила не только регистрируемую шумовую составляющую, но и амплитуду других регистрируемых импульсов легко выделялись и простым пороговым устройством. Вследствие того, что регистрация была дифференциальной, полярность спайка зависела от относительного положения нейрона между двумя регистрируемыми электродами, что также способствовало эффективной классификации и выделению спайков единичных элементов.

Стимуляция осуществлялась в условиях сравнительно тихой комнаты (уровень шума не превышал 50 дБ УЗД), а после ориентировочного определения порогов возникновения ответов на тональные посылки мы предъявляли сравнительно громкие сигналы (обычно в районе 80 дБ УЗД) которые реально могли наблюдаться в окружении животного. Такие сигналы включали звуки коммуникации кошек, звуки, излучаемые мелкими грызунами и певчими птицами и некоторые антропогенные звуки, включающие храп и музыкальные отрывки. Кроме того, использовали длительные тоны (обычно оптимальной для исследуемой клетки частоты несущей), глубоко модулированные низкочастотным шумом. Вновь заметим, что в подобном виде в обрабатывающие системы мозга передаются любые звуки, прошедшие узкополосную фильтрацию во внутреннем ухе.

Калибровались сигналы при расположении микрофона непосредственно перед ушной раковиной, что на самом деле ближе к реальной оценке поступающего звука, чем это осуществлялось в большинстве исследований на наркотизированных объектах с опущенной или удалённой ушной раковиной. В процессе эксперимента наряду с регистрацией нейрональной активности в локальной зоне коры фиксировались такие параметры жизнедеятельности животного как электроэнцефалограмма, кардиограмма, дыхательный ритм и некоторые динамические характеристики желудочно-кишечного тракта.

Результаты

В данной публикации мы осветим только основные особенности реакции клеток первичной слуховой коры ненаркотизированной кошки, уделяя особое внимание их отличию от сложившегося в литературе мнения о низкой лабильности и выраженной габитуации нейронов слуховой коры.

Практически во всех исследованных нами точках слуховой коры отмечалась фоновая активность одиночных нейронов. Эта активность могла

быть охарактеризована как фрактальный точечный временной процесс, в котором наблюдались пачки разнообразной длительности, и выявлялась положительная корреляция соседних интервалов.

При воздействии сложных сигналов значительной интенсивности мы не наблюдали жесткой связи между интенсивностью ответа и характеристической частотой той нейронной популяции, которая была локализована вблизи регистрирующего электрода. Более того во многих случаях даже сигнал характеристической частоты сразу после ответа на включение звука мог вызывать полное подавление фоновой активности непосредственно во время звучания. При этом степень избирательности реакции нейронов на сложные естественные стимулы, измеряемая по среднему значению импульсов в реакции на сигнал, обычно была невелика. При действии сигналов умеренной или высокой интенсивности ответ чаще всего сводился к синхронизации моментов появления спайков с некоторыми особенностями текущего спектра воспринимаемого стимула.

В настоящей работе мы приведём единичные примеры ответов, полученных в центральной области первичной слуховой коры (AI) исследуемого животного. Рассмотрим ответ клетки, имевшей характеристическую частоту вблизи 13 кГц, на длительный тональный сигнал данной частоты, модулированный повторяющимися отрезками низкочастотного шума со среднеквадратичным уровнем около 30 % в полосе 0–50 Гц (рис. 1, *а*) и 0–15 Гц (рис. 1, *б*). Длительность каждого из повторяющихся отрезков составляла 0.86с. при полосе шума 0–15 Гц и 0.512 с. при полосе 0–50 Гц. На двух верхних графиках иллюстрируется средняя частота импульсации исследуемого нейрона, взятая с частотой выборки 1 Гц, начиная с интервала, существенно предшествующего началу звука, и заканчивая после его окончания. Несмотря на сравнительно высокий (около 80 дБ УЗД) уровень сигнала с несущей частотой, соответствующей характеристической частоте нейрона, его предъявление, выделенное на рисунках интервалом между двумя треугольниками, практически не приводит к возрастанию средней частоты импульсации. Можно только отметить ослабление ответа после окончания сигнала с более высокой частотой модуляции. При этом само значение частоты импульсации весьма вариативно как в отсутствии сигнала, так и во время его действия.

Однако отсутствие сколь-нибудь резкого возрастания частоты спайков ещё не свидетельствует о том, что клетка не кодирует поступающую информацию. Во время действия звука ответ нейрона весьма четко воспроизводит изменения его амплитуды. Хотя на некоторых участках модулирующего периода мгновенная текущая частота импульсации достигает

100 имп/с, однако на других участках ответ оказывается существенно заторможенным даже по сравнению со спонтанной активностью.

Рис. 1. Ответы нейрона первичной слуховой коры на длительный тон характеристической частоты, модулированный по амплитуде низкочастотным шумом в полосе 0–50 Гц (*а*) и 0–15 Гц (*б*). Верхние графики показывают текущую частоту импульсации до сигнала, во время сигнала и после сигнала. Сигнал предъявляли в интервале, ограниченном треугольными значками. На нижних графиках приведены фазовые гистограммы, построенные на периоде модуляции во время действия сигнала, и демонстрирующие чёткое воспроизведение особенностей огибающей в импульсации клетки. На врезке нижнего графика рис. 1б приведена амплитудная огибающая амплитуды тонального сигнала характеристической частоты

Обсуждение

Наши результаты вполне естественно сопоставить с выводами недавно опубликованной работы, в которой, также как и в нашем случае, регистрация осуществлялась в первичной слуховой коре ненаркотизированной кошки [6]. Эксперименты велись в звукоизолированной камере с тщательным контролем параметров стимула. Сигналами служили только тональные отрезки и последовательности щелчков. Так же, как и в наших работах

было отмечено существенное отличие результатов от данных, полученных при действии различных анестезирующих агентов. Это отличие состояло, прежде всего, в гораздо большей лабильности и вариабельности активности нейронов слуховой коры у не анестезированных животных. С другой стороны, в работе [6] подчёркивалось, что многие клетки коры отличались высокой частотной избирательностью и нередко немонотонной зависимостью ответа от уровня тональных отрезков. В нашей работе мы не наблюдали столь высокой частотной избирательности, а немонотонная зависимость от уровня сигнала также отмечалась крайне редко. Кроме того, процент реагирующих на звук нейронов в нашем случае был существенно выше. Фактически значительное большинство исследованных нейронов реагировали (иногда резким изменением плотности импульсации, но чаще проявлением выраженной синхронизации со звуком) почти на все предъявляемые сигналы, включающие несколько десятков звуков возможных жертв (птицы, грызуны), храпы, коммуникационные внутривидовые сигналы, а также речевые и музыкальные фрагменты.

На наш взгляд отличия наших данных от результатов тех крайне малочисленных работ, которые были осуществлены на слуховой коре бодрствующих кошек, определяются, прежде всего, выбором стимулов. Нет реальных оснований полагать, что ответ нейронов коры полностью или даже существенно определяется только особенностями их реакции на тональные отрезки – звуки, которые не несут существенной экологической нагрузки. Последние работы, выполненные на иных объектах, но также в отсутствии наркоза, показывают, что частотно-пороговые кривые довольно плохо характеризуют способность нейронов коры реагировать на сложные стимулы [11]. Более того некоторые авторы свидетельствуют, что даже изучение реакции этих клеток на значительный набор разнообразных стимулов не гарантирует корректного предвидения их ответа на новый сигнал. Мне представляется, что многие нейроны, описанные в работе [6], которые оптимально реагировали при весьма низких уровнях тональных отрезков оптимальной частоты, при действии иных, более сложных и широкополосных сигналов умеренного и высокого уровня могут отвечать в весьма широком диапазоне интенсивностей и непредсказуемым образом.

Представляется, что наши данные можно рассматривать как веское свидетельство в пользу значительной роли именно временного распределения импульсации как основного переносчика информации о поступающем звуковом сигнале. Также, на мой взгляд, они свидетельствуют о том, что роль одиночного нейрона в кодировании сенсорной информации не слишком велика. В работе [12] удалось показать, что у животных, не подвергавшихся влиянию наркотических веществ, динамически формируемые ансамбли

клеток коры оказываются различными при действии разных звуков, в то время как при наркозе они слабо меняются при изменении сигнала. Некоторые другие авторы (см. [3]) также полагают возможным обсуждать гипотезу, сводящуюся к тому, что формирование динамических нейронных ансамблей непосредственно связано с ощущением самосознания как у животных, так и у человека.

Выводы

1. Как фоновая, так и вызванная импульсная активность нейронов коры ненаркотизированной здоровой кошки характеризуется значительной вариабельностью в диапазонах времён от десятков миллисекунд до десятков и даже сотен секунд.

2. При действии сигналов с выраженной амплитудной модуляцией в отдельных частотных каналах частота импульсации нейронов коры ненаркотизированной здоровой кошки не проявляет выраженной тенденции к монотонному ослаблению ответа на протяжении минут.

3. У многих нейронов первичной слуховой коры ненаркотизированной здоровой кошки реакция на сигнал сводится не к резкому возрастанию средней частоты импульсации, а к чёткой синхронизации ответа с временными особенностями действующего сигнала

4. Полученные данные свидетельствуют в пользу того, что кодирование сигналов в первичной слуховой коре осуществляется не за счёт активности единичных клеток, а вследствие динамического формирования распределённых ансамблей синхронно реагирующих нейронов.

Работа выполнялась на установке и при непосредственном участии доктора наук, главного научного сотрудника Института проблем передачи информации Ивана Николаевича Пигарева, трагически погибшего 14 июля 2021 года. Она была поддержана грантом РФФИ 19-04-00215а.

Список литературы

1. Hubel D.H., Henson C.O., Rupert A., Galambos R. Attention units in the auditory cortex // *Science.* 1959. Vol.129. P. 1279–1280. doi: 10.1126/Science.129.3358.1279.

2. Bibikov N.G. Functional studies of the primary auditory cortex in the cat // Neurosci. Behav. Physiology. 2021. Vol. 51. P. 1169–1189. doi.org/10.1007/s11055-021-01177-0.

3. Eggermont J. J. Properties of correlated neural activity clusters in cat auditory cortex resemble those of neural assemblies // J. Neurophysiol. 2006. Vol. 96. P. 746–764.

4. Laudanski J., Edeline J-M., Huetz C. Differences between spectro-temporal receptive fields derived from artificial and natural stimuli in the auditory cortex // PLOS ONE. 2012. Vol.7. No.11. e50539. doi:10.1371/journal.pone.0050539.

5. Bartlett E.L., Sadagopan S., Wang X. Fine frequency tuning in monkey auditory cortex and thalamus// J. Neurophys. 2011. Vol. 106. No. 2. P. 849–859. doi: org/ 10. 1152/ jn. 00559. 2010.

6. Middlebrooks J.C., Javier-Tolentino L.K., Arneja A., Richardson M.L. High spectral and temporal acuity in primary auditory cortex of awake cats// J. Assoc. Res. Otolaryngol. 2023. Vol. 24. No. 2. P. 197–215. doi: 10.1007/s10162-023-00890-6.

7. Бибиков Н.Г., Пигарев И.Н. Ответы корковых нейронов интактной кошки на некоторые окружающие естественные звуки // Материалы XXXIV сессии Российского акустического общества. 2022. С. 878–884. doi: org/10.34756/GEOS.2021.17.38058.

8. Бибиков Н.Г., Низамов С.В., Пигарев И.Н. Нейронные реакции коры мозга кошки на звуки, поступающие с фронтального направления (методические аспекты)// Материалы XXXIII сессии Российского акустического общества. 2020. С. 281-284. doi: ocean.ru/pdf/978-5-9901449-5-8-47.pdf/

9. Bibikov N.G., Makushevich I.V. Dynamics of background and evoked activity of neurons in the auditory cortex of the unanaesthetized cat // In: Kryzhanovsky B., Dunin-Barkowski W., Redko V., Tiumentsev Y. (eds) «Advances in Neural Comp., Machine Learn., and Cognitive Res. VI. Neuroinformatics 2022. Studies in Comp. Intelligence», Springer. 2023. P. 183–190.

10. Пигарев И.Н. Висцеральная теория сна // Журнал высшей нервной деятельности им. И.П. Павлова. 2013. Т. 63. С. 86–104.

11. Ni R, Bender D.A., Shanechi A.M., Gamble J.R., Barbour D.L. Contextual effects of noise on vocalization encoding in primary auditory cortex // J. Neurophysiol. 2016. Vol. 11. P. 713–727.

12. Filipchuk A., Schwenkgrub J., Destexhe A. et al. Awake perception is associated with dedicated neuronal assemblies in the cerebral cortex // Nat. Neurosci. 2022. Vol. 25. P. 1327–1338.

А.Л. ПРОСКУРА, С.О. ВЕЧКАПОВА, А.С. РАТУШНЯК
Федеральный исследовательский центр
информационных и вычислительных технологий, Новосибирск
annleop@mail.ru

ИНСУЛИН КАК МОДУЛЯТОР ПЛОТНОСТИ ГЛУТАМАТНЫХ РЕЦЕПТОРОВ*

В работе рассматриваются молекулярные перестройки в интерактоме дендритного шипика возбуждающего пирамидного нейрона поля CA1 гиппокампа под контролем гормона инсулина. Предложена реконструкция ключевых этапов сигнального пути рецептора инсулина, вовлекаемых в процессы модуляции синаптической нейротрансмиссии. Обсуждается протекторный эффект инсулина и его вклад в контроль плотности синаптических глутаматных рецепторов в гиппокампе.

Ключевые слова: *гиппокамп, дендритный шипик, синаптическая пластичность, глутаматные рецепторы, инсулин, инсулиновый рецептор.*

Введение

Дендритный шипик формирует постсинаптическую часть пирамидных нейронов высших отделов мозга. На его плазматической мембране располагается целый спектр рецепторов различной природы, которые организованы в многоуровневую систему контроля глутаматергической нейротрансмиссии [1–6].

Инсулин вырабатывается поджелудочной железой и посредством насыщаемого транспорта поступает в мозг [7, 8], где связывается со своими рецепторами (ИР). В периферических тканях он, главным образом обеспечивает метаболизм глюкозы и липидов. В нейронах ИР участвует в анорексигенных реакциях, формировании памяти и выживании нейронов [7, 9–11]. Нарушение передачи сигналов инсулина вызывает окислительное повреждение нейронов и подвергает мозг риску развития нейродегенерации [12].

Сигнальный путь ИР в периферических тканях достаточно хорошо представлен в литературе [7, 13], в отличие от нейронов, что делает задачу описания его сигнального пути в интерактоме дендритного шипика высоко

* Представленные в статье данные получены в ходе реализации базового проекта фундаментальных исследований 122010800028-4 (ЕГИСУ).

актуальной. На основе разрозненных экспериментальных данных, опубликованных в базе данных PubMed, мы реконструировали межмолекулярные взаимодействия и предложили модель механизма изменения плотности синаптических АМПА рецепторов под контролем инсулина.

1. Инсулин в интерактоме дендритного шипика

1.1. Визуализационная модель синаптической пластичности

В базе данных GeneNet (РОСПАТЕНТ № 990006 от 15/02/1999) представлена визуализационная модель межбелковых взаимодействий, регулирующих длительное усиление синаптической эффективности в течение долговременной потенциации (ДВП) [14, 15, 43]. которая использовалась нами в качестве инструмента анализа молекулярных путей реализации эффектов инсулина на синапсах гиппокампа.

Ионотропные глутаматные рецепторы, а именно НМДА (N-метил-D-аспартат) (НМДАР) и АМПА (α-амино-3-гидрокси-5-метил-4-изоксазолпропионовая кислота) (АМПАР) типов являются ключевыми для ДВП. Варианты АМПАР во взрослом гиппокампе: субъединицы GluR2, GluR3 – GluR2/3-АМПАР, GluR1 – как гомо-, так и гетеротетрамеры – GluR1-АМПАР [16]. Рецепторы организованы в макрокомплексы с белками постсинаптического уплотнения (ПСУ) [15, 17], а именно скаффолд-белками, например PSD95 (Postsynaptic density protein) и адаптерными белками [18–25]. В частности, белки семейства Shank (SH3 and multiple ankyrin repeat domains protein) обеспечивают посадку АМПАР в зоне синаптического контакта [26–28].

GluR2/3-АМПАР наиболее представлены на синапсах взрослого гиппокампа, их плотность не статична, поддерживается конститутивным рециклированием и зависит от предшествующей активности, метаболического состояния и может модулироваться разнообразными агентами, в частности гормонами [29, 30]. Они обеспечивают базовую активность синапса, а также деполяризацию плазматической мембраны (до ~ –50 мВ), что приводит к активации НМДАР и индукции ДВП [30–32].

После индукции ДВП происходит кратковременный интенсивный вход ионов кальция через НМДАР, что запускает сети сигнальных путей ряда протеинкиназ и фосфатаз [15], введение дополнительного пула GluR1-АМПАР и их закрепление с белками ПСУ – SAP97 и Shank, а также ряд модификаций [32–34], а также интенсификация выведения GluR2/3-АМПАР из синапсов, для чего необходимо фосфорилирование GluR2 протеинкиназой ПКС [35] (рис. 1).

Рис. 1. Схематичное представление ключевых этапов изменения плотности АМПАР на синапсах после индукции ДВП: ПСУ – постсинаптическое уплотнение; ВСЗ – внесинаптическая зона; GluR1-АМПАР – содержат субъединицу 1 типа; GluR2/3-АМПАР – субъединицы 2 и 3 типов; НМДАР – НМДА рецепторы; ФИ(4)Ф – фосфатидилинозит-4-монофосфат; ФИ(4,5)Ф2 – фосфатидилинозит-4,5-дифосфат; ПКА – протеинкиназа А; ПКС – протеинкиназа С; CaMKII – кальций-кальмодулин регулируемая протеинкиназа. P – фосфатная группа (модификация АМПАР). Ca^{2+} – входящие ионы кальция. Выведение синаптических GluR2/3-АМПАР: комплексы PICK (Protein Interacting with C Kinase – 1), GRIP (Glutamate-receptor-interacting protein) и ПКС. Введение на синапсы GluR1-АМПАР и их закрепление: протеинкиназы ПКА и ПКС, а также белки ПСУ – SAP97 (Synapse-associated protein 97), Shank (SH3 and multiple ankyrin repeat domains protein), PSD95 (Postsynaptic density protein)

Новая увеличенная за счет GluR1-АМПАР плотность на синапсе АМПАР обеспечивает увеличение его эффективности. Развитие ДВП сопровождается ее корректировкой, а долговременное поддержание – заменой GluR1-АМПАР на GluR2/3-АМПАР, чья плотность будет поддерживаться путем конститутивного рециклирования [15] и зависеть от модулирующих воздействий, таких как новая структура макрокомплексов рецепторов, метаболический статус, наличие повреждающих факторов и пр.

1.2. Сигнальный путь рецептора инсулина на синапсе

Рецептор инсулина (ИР) (продукт гена INSR) является трансмембранным протеином, относится к классу рецепторных тирозинкиназ и экспрессируется во всех отделах мозга [7]. Считается, что ИР и его субстрат IRS

(insulin receptor substrate) активируют, главным образом, сигнальный путь фосфатидилинозитол-3-киназы (ФИЗК), что приводит к накоплению на мембране пула ФИФ3 (фосфатидилинозитол-(3,4,5)-трифосфат) за счет фосфорилирования 3 позиции в инозитольном кольце ФИФ2 (фосфатидилинозит-4,5-дифосфат) – реакция ФИФ2 -> ФИФ3 [7, 15] (рис. 2).

Рис. 2. Схематичное представление сигнального пути инсулина в дендритных шипиках пирамидных нейронов поля CA1 гиппокампа: ПСУ – постсинаптическое уплотнение; СПМ – синаптическая мембрана АМПАР – АМПА рецепторы; GluR1 – субъединица 1 типа АМПАР; GluR2/3 – АМПАР с субъединицами 2 и 3 типов; ФИЗК – фосфатидилинозитол-3-киназа; ФИФ2 – фосфатидилинозит-4,5-дифосфат; ФИФ3 – фосфатидилинозитол-(3,4,5)-трифосфат; IRSp53/Baiap2 – субстрат инсулинового рецептора молекулярной массой 53 кДа (Insulin receptor substrate protein of 53 kDa/Brain-specific angiogenesis inhibitor 1-associated protein 2); IRS – субстрат инсулинового рецептора (insulin receptor substrate); Shank – белок, содержащий SH3 домен и множество анкириновых повторов (SH3 and multiple ankyrin repeat domains protein); PTEN – фосфатаза с двойной субстратной специфичностью, продукт гена PTEN (phosphatase and tensin homolog deleted on chromosome 10); цАМФ – циклический аденозинмонофосфат; ДАГ – диацилглицерин; ПКС – протеинкиназа С; ПКА – цАМФ-зависимая протеинкиназа А; ФЗК – фосфоинозитид-зависимая протеинкиназа 1 (PDK1 (Phosphoinositide-dependent kinase-1)); H2O2 – перекись водорода; АФК – активные формы кислорода.

– межмолекулярные реакции; – пролонгация активности; – блокирование процесса

ФИФ3 являются сайтами закрепления ряда белков, в частности ФЗК – фосфоинозитид-зависимой протеинкиназы 1 ((PDK1 (Phosphoinositide-

dependent kinase-1)), которая, помимо прочего, пролонгирует активность ПКС и ПКА [36].

Накопление на мембране пула ФИФ3 возможно в ситуации ингибирования активности PTEN – протеинфосфатазы с двойной субстратной специфичностью, продукта гена PTEN (сокр. от англ. phosphatase and tensin homolog deleted on chromosome 10), что может достигаться как через ее фосфорилирование рядом протеинкиназ [37, 38], так и ингибированием активного центра перекисью водорода и/или АФК [7]. PTEN дефосфорилирует фосфоинозитиды в позиции 3 инозитольного кольца (реакция ФИФ3 -> ФИФ2) (см. рис. 2).

Еще одним субстратом тирозинкиназы ИР является адаптерный белок ПСУ – Baiap2 (Brain-specific angiogenesis inhibitor 1-associated protein 2), синоним IRSp53 (Insulin receptor substrate protein of 53 kDa) [39], который закрепляется на мембране через скаффолд-белки ПСУ в участках, обогащенных ФИФ2 и ФИФ3 [40].

Baiap2/IRSp53 в ПСУ прямо взаимодействует со скаффолд-белками семейства Shank (белок, содержащий SH3 домен и множество анкириновых повторов (SH3 and multiple ankyrin repeat domains protein), снижая число слотов для закрепления вводимых после индукции ДВП АМПАР [41]. Имеются данные, что Baiap2/IRSp53 способствует выведению из ПСУ НМДАР [40, 42]. Таким образом, IRSp53 ограничивает количество синаптических глутаматных рецепторов на ПСУ и тем самым влияет на синаптическую пластичность, а не на морфологию дендритов.

В присутствии перекиси водорода и/или АФК (например, в ситуации предшествующей значительной синаптической активности) ИР будет запускать накопление на мембране ФИФ3 через ФИ3К-сигнальный каскад, что поддерживает интенсификацию процессов выведения GluR2/3-АМПАР и введения GluR1-АМПАР после индукции НМДАР-зависимой ДВП. Кроме того, ПКС и сам ИР будут способствовать закреплению в ПСУ белков Baiap2/IRSp53, что в корне способно переформатировать конфигурацию глутаматных рецепторов на плазматической мембране синапса, способствуя, как выведению синаптических НМДАР, так и ограничению свободных слотов для закрепления вводимых АМПАР.

Заключение

Основной сигнальный каскад ИР может реализоваться в ситуации блокировки его антагониста, фосфатазы PTEN, что происходит в присутствии активных форм кислорода, которые можно рассматривать как мессен-

джеры в сигнальном пути инсулина. Таким образом, уже на уровне синаптической мембраны инсулин демонстрирует свой протекторный эффект, обеспечивая, помимо прочих событий, функционирование шипика и поддержание баланса возбуждения/торможения в синаптических сетях мозга.

Список литературы

1. Collins S.A., Husi H., Yu L., Brandon J.M., Anderson C.N.G., Blackstock W.P., Choudhary J.S., Grant S.G.N. Molecular characterization and comparison of the components and multiprotein complexes in the postsynaptic proteome // J. Neurochem. 2007. V. 97. P. 16–23.

2. Proskura A.L., Ratushnyak A.S., Vechkapova S.O., Zapara T.A. Synapse as a multi-component and multi-level information system // Studies in computational intelligence. 2018. V. 736. P. 186–192.

3. Proskura A.L., Vechkapova S.O., Ratushnyak A.S. Dopamine and hippocampal synaptic plasticity // Procedia Computer Science. 2020. V.169. P. 668–672.

4. Berrout L., Isokawa M. Ghrelin upregulates the phosphorylation of the GluN2B subunit of the NMDA receptor by activating GHSR1a and Fyn in the rat hippo-campus // Brain Res. 2018. V. 1678. P. 20–26.

5. Harvey J., Solovyova N., Irving A. Leptin and its role in hippocampal synaptic plasticity // Prog. Lipid Res. 2006. V. 45. No 5. P. 369–378.

6. Бондарева В.М., Чистякова О.В. Инсулин и инсулинрецепторная сигнальная система мозга // Нейрохимия. 2007. Т. 23. No 31. С. 8–20.

7. Помыткин И.А., Красильникова И.А., Пинелис В.Г., Каркищенко Н.Н. Инсулиновый рецептор в мозге: новая мишень в лечении центральной инсулиновой резистентности // Биомедицина. 2018. V. 3. С. 17–34.

8. Stanley M., Macauley S. L., Caesar E. E., Koscal L. J., Moritz W., Robinson G. O., Roh J., Keyser J., Jiang H. and Holtzman D. M. The effects of peripheral and central high insulin on brain insulin signaling and amyloid-beta in young and old APP/PS1 mice // J. Neurosci. 2016. V. 36. P. 11704–11715.

9. Zhao F., Siu J.J., Huang W., Askwith C., Cao L. Insulin modulates excitatory synaptic transmission and synaptic plasticity in the mouse hippocampus // Neuroscience. 2019. V. 411. P. 237–254.

10. Salcedo I., Tweedie D., Li Y., Greig N.H. Neuroprotective and neurotrophic actions of glucagon-like peptide-1: an emerging opportunity to treat neurodegenerative and cerebrovascular disorders: Neurological benefts of GLP-1 receptor activation // Br J Pharmacol. 2012. V. 166. No 5. P. 1586–1599.

11. Yu L-Y, Pei Y. Insulin Neuroprotection and the Mechanisms // Chin Med J (Engl). 2015. V. 128. No 7. P. 976–981.

12. Muller A.P., Haas C.B., Camacho-Pereira J., Brochier A.W., Gnoatto J., Zimmer E.R., de Souza D.O., Galina A., Portela L.V. Insulin prevents mitochondrial generation of H□O□ in rat brain // Exp Neurol. 2013. V. 247. P. 66–72.

13. Whites M.F., Kahn C., R. The Insulin Signaling System // The Journal of Biological Chemistry. 1994. V. 269, No. 1. P. 1–4.

14. Bliss T.V., Collingridge G.L. A synaptic model of memory: long-term potentiation in the hippocampus // Nature. 1993. V. 361. P. 31–39.

15. Проскура А.Л., Малахин И.А., Турнаев И.И., Суслов В.В., Запара Т.А., Ратушняк А.С. Межмолекулярные взаимодействия в функциональных системах нейрона // Вавиловский журнал генетики и селекции. 2013. Т. 17. С. 620–628.

16. Wenthold R.J., Petralia R.S., Blahos J., Niedzelski A.S. Evidence for multiple AMPA receptor complexes in hippocampal CA1/CA2 neurons // J. Neurosci. 1996. V. 16. No 6. P. 1982–1989.

17. Proskura A.L., Ratushnyak A.S., Vechkapova S.O., Zapara T.A. Synapse as a multi-component and multi-level information system // Studies in computational intelligence. 2018. V. 736. P. 186–192.

18. Chen X., Winters C., Azzam R., Li X., Galbraith J.A., Leapman R.D., Reese T.S. Organization of the core structure of the postsynaptic density // Proc. Natl. Acad. Sci. U S A. 2008. V. 105. No 11. P. 4453–4458.

19. Manser E., Loo T.H., Koh C.G., Zhao Z.S., Chen X.Q., Tan L., Tan I., Leung T., Lim L. PAK kinases are directly coupled to the PIX family of nucleotide exchange factors // Mol Cell. 1998. V. 1. No 2. P. 183–192.

20. Uruno T., Liu J., Li Y., Smith N., Zhan X. Sequential interaction of actin-related proteins 2 and 3 (Arp2/3) complex with neural Wiscott-Aldrich syndrome protein (N-WASP) and cortactin during branched actin filament network formation // J. Biol. Chem. 2003. V. 278. No 28. P. 26086–26093.

21. Neuhoff H., Sassoè-Pognetto M., Panzanelli P., Maas C., Witke W., Kneussel M. The actin-binding protein profilin I is localized at synaptic sites in an activity-regulated manner // Eur. J. Neurosci. 2005. V. 21. No 1. P. 15–25.

22. Schubert V., Dotti C.G. Transmitting on actin: synaptic control of dendritic architecture // J. Cell. Sci. 2007. V. 120. No 2. P. 205-212.

23. Rex C.S., Chen L.Y., Sharma A., Liu J., Babayan A.H., Gall C.M., Lynch G. Different Rho GTPase-dependent signaling pathways initiate sequential steps in the consolidation of long-term potentiation // J. Cell. Biol. 2009. V. 186. P. 85–97.

24. Iida J., Ishizaki H., Okamoto-Tanaka M., Kawata A., Sumita K., Ohgake S., Sato Y., Yorifuji H., Nukina N., Ohashi K., Mizuno K., Tsutsumi T., Mizoguchi A., Miyoshi J., Takai Y., Hata Y. Synaptic scaffolding molecule alpha is a scaffold to mediate N-methyl-D-aspartate receptor-dependent RhoA activation in dendrites // Mol. Cell. Biol. 2007. V. 27. No 12. P. 4388–4405.

25. Honkura N., Matsuzaki M., Noguchi J., Ellis-Davies G.C., Kasai H. The subspine organization of actin fibers regulates the structure and plasticity of dendritic spines // Neuron. 2008. V. 57. P. 719–729.

26. Peng J., Kim M.J., Cheng D., Duong D.M., Gygi S.P., Sheng M. Semiquantitative proteomic analysis of rat forebrain postsynaptic density fractions by mass spectrometry // J. Biol. Chem. 2004. V. 279. No 20. P. 21003–21011.

27. Chen X., Vinade L., Leapman R.D., Petersen J.D., Nakagawa T., Phillips T.M., Sheng M., Reese T.S. Mass of the postsynaptic density and enumeration of three key molecules // Proc Natl Acad Sci U S A. 2005. V. 102. No 32. P. 11551–11556.

28. Cheng D., Hoogenraad C.C., Rush J., Ramm E., Schlager M.A., Duong D.M., Xu P., Wijayawardana S.R., Hanfelt J., Nakagawa T., Sheng M., Peng J. Relative and

absolute quantification of postsynaptic density proteome isolated from rat forebrain and cerebellum // Mol Cell Proteomics. 2006. V. 5. No 6. P. 1158–1170.

29. Greger I.H., Esteban J.A. AMPA receptor biogenesis and trafficking // Curr. Opin. Neurobiol. 2007. V. 17. No 3. P. 289–297.

30. Newpher T.M, Ehlers M.D. Glutamate receptor dynamics in dendritic microdomains // Neuron. 2008. V. 58. P. 472–497.

31. Nowak L., Bregestovski P., Ascher P., Herbet A., Prochiantz A. Magnesium gates glutamate-activated channels in mouse central neurones // Nature. 1984. V. 307. No 5950. P. 462–465.

32. Tanaka H., Hirano T. Visualization of subunit-specific delivery of glutamate receptors to postsynaptic membrane during hippocampal long-term potentiation // Cell. Rep. 2012. V. 1. P. 291–298.

33. Braithwaite S.P., Meyer G., Henley J.M. Interactions between AMPA receptors and intracellular proteins. Neuropharmacology // 2000. V. 39. N. 6. P. 919–930.

34. Lee HK, Barbarosie M, Kameyama K, Bear MF, Huganir RL. Regulation of distinct AMPA receptor phosphorylation sites during bidirectional synaptic plasticity. Nature. 2000;405(6789):955–959.

35. Seidenman K.J., Steinberg J.P., Huganir R., Malinow R. Glutamate receptor subunit 2 Serine 880 phosphorylation modulates synaptic transmission and mediates plasticity in CA1 pyramidal cells // J Neurosci. 2003. V. 23. No 27. P. 9220–9228.

36. Pearce LR, Komander D, Alessi DR. The nuts and bolts of AGC protein kinases. Nat Rev Mol Cell Biol. 2010;11(1):9–22.

37. Moult PR, Cross A, Santos SD, Carvalho AL, Lindsay Y, Connolly CN, Irving AJ, Leslie NR., Harvey J. Leptin regulates AMPA receptor trafficking via PTEN inhibition. J Neurosci. 2010;30:4088–4101.

38. Al-Khouri AM, Ma Y, Togo SH, Williams S, Mustelin T. Cooperative phosphorylation of the tumor suppressor phosphatase and tensin homologue (PTEN) by casein kinases and glycogen synthase kinase 3beta. J Biol Chem. 2005;280(42):35195–35202.

39. Heung MY, Visegrady B, F?tterer K, Machesky LM. Identification of the insulin-responsive tyrosine phosphorylation sites on IRSp53. Eur J Cell Biol. 2008;87(8-9):699–708.

40. Hori K, Yasuda H, Konno D, Maruoka H, Tsumoto T, Sobue K. NMDA receptor-dependent synaptic translocation of insulin receptor substrate p53 via protein kinase C signaling. J Neurosci. 2005;25(10):2670–2681.

41. Sawallisch C, Berh?rster K, Disanza A, Mantoani S, Kintscher M, Stoenica L, Dityatev A, Sieber S, Kindler S, Morellini F, Schweizer M, Boeckers TM, Korte M, Scita G, Kreienkamp HJ. The insulin receptor substrate of 53 kDa (IRSp53) limits hippocampal synaptic plasticity. J Biol Chem. 2009;284(14):9225–9236.

42. Pomytkin IA. H2O2 signalling pathway: a possible bridge between insulin receptor and mitochondria. Curr Neuropharmacol. 2012;10(4):311–320.

43. http://wwwmgs.bionet.nsc.ru/mgs/gnw/genenet/viewer/AMPA.html

Г.С. ВОРОНКОВ
Московский государственный университет имени М.В. Ломоносова
av13675@yandex.ru

СУЩЕСТВУЕТ ЛИ ВНУТРИМОЗГОВОЙ ЭКРАН ДЛЯ СУБЪЕКТИВНЫХ ЗРИТЕЛЬНЫХ ОБРАЗОВ

Субъективный зрительный образ (СЗО) **реального зрительного пространства** (РЗП) не есть результат активности элементов непосредственно сетчатки. Общепринято, что СЗО обеспечивается активностью центральных зрительных структур мозга. Однако, нейронный экран в мозге с изображением РЗП, подобным таковому в СЗО, не обнаружен. В работе делается попытка идентифицировать, в каком **объективном** виде осуществляется в мозге репрезентация **точных координат** точек РЗП, подобная таковой у СЗО.

Ключевые слова*: ощущение видения, субъективный образ, зрительное пространство, механизм соответствия, психофизиологическая проблема.*

Введение с постановкой задачи

Видимое монокулярно, при неподвижной голове **реальное зрительное пространство (РЗП**) ограничено, как рамкой, глазницей (рис. 1); ощущение видения РЗП (и всего, что в нём находится) есть его **субъективный зрительный образ (СЗО**); СЗО гомотетичен (подобен) РЗП, координаты их соответствующих друг другу точек пропорционально идентичны друг другу – ибо, СЗО, как бы светом, проецируется на РЗП и сливается с ним (надавливая на глазное яблоко, можно сместить СЗО относительно РЗП). Более всего СЗО сходен (по точности изображения) с оптическим изображением РЗП на сетчатке (когда взор направлен в центр РЗП). Однако СЗО не есть результат активности элементов непосредственно сетчатки; об этом свидетельствуют факты, например: (1) СЗО остается константным при движении взора по РЗП (феномен константности восприятия РЗП) и (2), наоборот, СЗО может изменяться при постоянстве предъявляемого РЗП (феномен куб Неккера), (3) субъект не видит слепого пятна сетчатки. Общепринято, что феномен СЗО обеспечивается активностью центральных зрительных структур мозга. Тем не менее, центральная структура (нейронный экран) с изображением РЗП, подобным таковому на сетчатке, не обнаружена – известные «топографические карты» в зрительной коре не идут ни в какое сравнение (по точности «картирования» РЗП) с СЗО [1]; также, нет

общепринятого представления о формировании, субстанционности и самом существовании СЗО в центрах (как картине, подобной на сетчатке). Общим у авторов, обсуждающих эти вопросы и подобные, но более широко поставленные вопросы (например, о природе квалия), является признание концепта, что путь к их решению лежит через установление, в каком **объективном** виде, т.е., где и как в **нейронной мозговой модели** репрезентированы **характеристики** (свойства) внешнего мира [2–5].

Предлагаемая здесь работа – попытка идентифицировать, в каком **объективном** виде осуществляется **представительство** нейронными зрительными структурами, казалось бы, основной, атрибутивной характеристики точек РЗП, – их **точных координат (ТК),** сопоставимое с представительством их у СЗО. Анализ этого вопроса составляет содержание раздела Основной текст. В результате анализа автор приходит к следующим основным выводам: 1) ТК точек РЗП задаются самой зрительной системой и репрезентированы в объективном виде только её эфферентной частью – мотонейронами и глазодвигательным аппаратом; 2) ТК реализуются в полярной системе координат, в физическом («макетном») виде; 3) экраном, на котором реализуются эти ТК, является само РЗП. Эти выводы сделаны и кратко обсуждаются в ходе изложения основного текста с разных точек зрения – в нейрофизиологическом, психофизиологическом и информационном аспектах.

В работе используются представления и заключения из предыдущих работ автора [6–12, 14], касающихся тем данной статьи, в том числе, упомянутых выше феноменов – константность восприятия РЗП [6], куб Неккера [7], слепое пятно [8].

В «Основном тексте» материал излагается в форме отдельных озаглавленных подразделов, в которых описываются факты и представления, являющиеся обоснованиями для делаемых в работе выводов.

Основной текст

(1). Модельный подход (МП). Согласно нейрофизиологическому **Модельному подходу** (МП), мозг является, в широком понимании, нейронной моделью внешнего мира во всех его проявлениях. Большой фактический нейрофизиологический материал последних десятилетий только подтверждает МП.* Поэтому вопрос, поставленный во Введении данной статьи – в

* Автор следует этому подходу с момента первого его описания [9], развивая [10, 11] и дополняя его (в частности, данная работа).

каком виде представлены в зрительной системе ТК точек РЗП – имеет, казалось бы, априорный ответ: ТК представлены (репрезентированы) **нейронами (**как данностями, своего рода символами**)** зрительных структур. Тем не менее, материал данной работы, а также нескольких предшествующих работ, позволяет сделать следующее дополнение к этому ответу. Так, ранее выявлено, что характеристика «зеркальность» репрезентируется нейронной моделью физическим, или, другими словами, **«макетным»** («наглядным») способом – в виде «топографических карт» [7, 12]. Этот «прецедент» сделал более доступным для понимания факт, что ТК точек РЗП тоже представлены в определенной степени «макетным» способом (см. (4), (5), (9)). Таким образом, характеристики зрительного мира представлены в зрительной системе не только в символьном, но еще и в физическом («макетном») виде. В литературе представление о том, что в мозгу имеет место только символьная репрезентация внешнего мира до сих пор не оспаривалось – так, например, согласно В.С. Рамачандран [4], в мозгу имеет место «лишь «**символическое**» описание, которое не имеет сходства с «**физическим**» описанием».

*(2). Функция **топографических** (ретинотопических) проекций.* Если стимулировать (раздражать) электрическим током или небольшим пятнышком света непосредственно сетчатку и «идти вдоль какой-либо линии на сетчатке, то проекции последовательных точек этой линии в НКТ и в коре также образуют одну непрерывную линию» – вот, пожалуй, самое адекватное определение того, что называют, как правило, ретинотопической (или просто, «топической» или, «точка в точку» – см. [13]) проекцией; это определение дано в книге Д. Хьюбеля [1], сам он именует эту проекцию «топографическим отображением». Однако наиболее близким к действительно **топографическому** являются только изображение на сетчатке, создаваемое оптическим аппаратом глаза, и СЗО; "топографическое изображение" (или, проекция) в центральных зрительных структурах сильно искажено (в сравнении с сетчаточным и СЗО). Таким образом, топографические проекции (карты) всех афферентных полей коры не репрезентируют **точные координаты** точек РЗП . Основной же факт, позволяющий сделать это заключение, состоит в том, что изображение РЗП на сетчатке (и, следовательно, в полях коры) **изменяется** при смещении взора по РЗП, т.е., что каждая точка сетчатки (и, следовательно, топографической проекции) получает активность после смещения взора от новой точки РЗП. В чем же состоит тогда функция этих «топографических» карт? В предыдущих наших работах, в частности [12, 14,] показано, что в зрительной системе репрезентирована характеристика РЗП, **обобщающая** пространственные отношения между собой всех его точек, эта характеристика – **зеркальность** РЗП;

описаны **морфологические** механизмы зеркальных преобразований в зрении и разнообразные **функциональные** проявления работы этих механизмов, также показано, что этих механизмов достаточно, чтобы зеркальность СЗО была идентична зеркальности РЗП. Таким образом, есть основания полагать, что функция «топографических проекций» РЗП состоит (как уже отмечено выше, в (1)) в репрезентации характеристики РЗП – его зеркальности (но не в репрезентации ТК его точек).

Рис. 1. Реальное зрительное пространство (РЗП=ЗП),
поле зрения (ПЗ) и ограничивающая их рамка глазницы.
Показаны две позиции глазного яблока
(в условиях одного и того же положения головы). Остальное описание в тексте

(3) Поле зрения (ПЗ) и реальное зрительное пространство (РЗП). В настоящей работе является важным различать ПЗ и ЗП и их представительство структурами зрительной системы. На рис. 1 показано, что видение РЗП (при неподвижной голове) ограничено рамкой глазницы*; при направлении взгляда (= взора) в центр РЗП поле зрения (ЗП) занимает его почти полностью. При смещении взора** по РЗП часть ПЗ выходит за рамку глазницы (т.е., часть ПЗ не проецируется на сетчатку совсем), картинка на сетчатке при этом изменяется. Поскольку в афферентные поля зрительной коры (V1,

* Слово «глазница» здесь несколько условное название – так как, часть ограничивающей рамки принадлежит, в частности, носу [15].

** Взор – направление "луча" из центра fovea сетчатки в РЗП.

V2, …) сетчатка проецируется «точка в точку» (см. (2)), эти поля коры получают активность только от той части РЗП, которая охватывается полем зрения (ПЗ), т.е. проекция РЗП в афферентных полях коры такая же (по охвату РЗП), как у сетчатки. СЗО же при этом охватывает практически всё РЗП – СЗО зрительного пространства (РЗП) практически не зависит от смещения взор по РЗП (при неподвижной голове). Этот феномен константности восприятия РЗП, проявляющийся в СЗО, коррелирует с подобным свойством у нейронного поля коры V 7* (цит. по [3]). В нашей работе [6] обсуждается возможный нейрофизиологический механизм, обеспечивающий этот феномен.

(4) Раздельное представительство в зрительной системе характеристик точек РЗП. Известно, что такие качественные характеристик точек РЗП как цвет, яркость, движение и другие представлены афферентными нейронами (как данностями) в разных зрительных полях коры (V1, V2, …). Пространственная же характеристика РЗП **зеркальность**, представлена в этих полях в «макетном» виде» – «топографическими» проекциями (см. (2)). Очевидно, что все названные выше характеристики (включая характеристику **зеркальность**) являются проявлениями **объективных** свойств объектов внешнего мира, воздействующих на субъект. В то же время характеристика **«точные координаты» (ТК)** точек РЗП, не представлена нейронами афферентных полей**. Это обстоятельство согласуется с обосновываемым здесь представлением (см. (7)), что характеристика ТК является **субъективной** характеристикой, и что, в частности, поэтому не следует ожидать, что характеристика **ТК** репрезентирована (представлена) воспринимающей (афферентной) частью зрительной системы.

(5) Репрезентация точных координат (ТК) точек РЗП. Как уже отмечено выше, наиболее точно, почти идеально РЗП репрезентировано (представлено) в зрительной системе виде СЗО. Об этом свидетельствует то, что «проекция» СЗО практически «сливается» с РЗП (т. е., что координаты точек СЗО пропорционально идентичны таковым РЗП), и то, что разрешение СЗО (острота зрения) является очень высоким – человек различает две точки, расстояние между которыми не превышает размера фоторецептора (2,5 мкм). Наиболее сходным с СЗО (по названным характеристикам) является изображение РЗП на сетчатке, создаваемое оптической проекцией (когда взор фиксирован в центре рамки, ограничивающей РЗП). Однако, как

* Однако это не значит, что в V 7 нейроны располагаются подобно точкам в РЗП.

** Из существования проекции «точка в точку» между (между сетчаткой и афферентными зрительными центрами вовсе не следует точное подобие создаваемых на них картин РЗП (см. (2)).

уже отмечалось выше, СЗО не есть результат активности непосредственно ни сетчатки, ни центральных афферентных нейронных полей. В то же время, поскольку СЗО обеспечивается (является следствием) активностью **нейронной** мозговой модели*, **точные** координаты РЗП должны быть каким-то образом представлены в зрительной системе и структурно. И, действительно, представительство ТК точек РЗП, сходное (по точности) с таковым у СЗО, обнаруживается. Но, – только в эфферентной части зрительной системы. Это представительство проявляется как функционально, так и морфологически. Функционально, в том, что луч взора можно направить, как показывает опыт, практически в любую точку РЗП (с точностью, которую обеспечивает СЗО). Морфологически, – в виде глазодвигательного аппарата и эфферентной зрительной системы, обеспечивающих управление движениями глазного яблока, т.е., взором. (Глазодвигательный аппарат выступает в виде своего рода «макета» полярной системы координат.)

(6) Точные координаты (ТК) точек РЗП, в которые направляется взор, «задаются» ***самой*** *зрительной системой.*

Взор направляется в точки РЗП либо произвольно, либо непроизвольно. Очевидно, что в первом случае управление взором обеспечивается системой, которую в целом можно обозначить как «система внимания».

В то же время, «непроизвольное» управление тоже обеспечивается, как показали уже первые записи саккадических движений глаз [16], системой внимания (но работающей в значительной степени без жесткого сознательного контроля).

Поскольку, как показано выше ((2), (5)), в афферентной части зрительной системы ТК точек РЗП не представлены, они (ТК) представлены **только** в эфферентной зрительной системе. Кроме того, уже простые наблюдения (и литературные данные) свидетельствуют, что система управления взором **формируется**. Это происходит в период онтогенеза субъекта (путем сенсорного обучения).

Таким образом, в «зрелой» зрительной системе представительство ТК точек РЗП (ограниченного постоянной рамкой глазницы; рис. 2) уже сформировано (они представлены в эфферентной системе (см. (5)). Система внимания «использует» эти ТК, чтобы выбрать и направить взор в ту точку, от которой ей «необходимо» получить активность (рис. 2); этот выбор происходит из среды актуально активированных афферентных нейронов, ТК

* Вся практика нейрофизиологическая исследований свидетельствует, что субъективные ощущения сопровождают нейронную активность, но не наоборот.

которых ей «известны,» – так как система (внимания) сама направляла взор к «точке» РЗП, от которой получила актуальную* активность.

Рис. 2. Схема процесса восприятия в зрительной системе

5, 6, 7, … – мотонейроны, репрезентирующие ТК точек РЗП=ЗП; обведенные кружком **5, 6, 7** … – афферентные нейроны, не репрезентирующие ТК точек ЗП 5, 6, 7, … (но эти ТК "известны" системе внимания). Остальное описание в тексте (см. (9)).

(*7) Дополнение к положению, что зрительная система разбивает РЗП на точки.* Формирование ТК (точнее, – морфологического представительства ТК; см. (5)) и есть, по-видимому, разбиение РЗП (точнее, – ограниченного рамкой глазницы пространства**) на точки. Тогда, точку РЗП правильнее определить как **место** (в РЗП), куда направлен, или, может быть направлен, взор. Из такого понимание **ТК точек РЗП** и самих **точек РЗП** следует, что характеристика «ТК точки РЗП» есть **субъективная** характеристика, и что поэтому, в отличие от других (**объективных**) характеристик, характеристика «**ТК**» не должна быть представлена в афферентной (воспринимающей) зрительной системе. В работе также принимается, что количество ТК («точек»), на которые разбито РЗП (пространство рамки), конечно; количество «точек» равно количеству возможных **точек фиксации** взора; это принимаемое положение является составным компонентом в механизме, обеспечивающем феномен **константность восприятия РЗП** (см. [6]).

* Как актуальная определяется здесь активность, поступающая в период фиксированного положение взора.

** По умолчанию, РЗП в рамке выступает как плоское (2D) пространство. В работе [7] обосновывается, кроме того, что РЗП воспринимается как 3D пространство – как «дополнительно» разбитое на слои (по глубине) пространство.

(8) Дополнительные пояснения к используемым в работе терминам «точка РЗП» и «точка в проекциях РЗП и ПЗ». Согласно нейрофизиологическим данным, нейроны афферентных зрительных центров не связаны с рецепторами 1:1 (см., например, [1]). Как правило, на одном нейроне **конвергируют** многие соседние рецепторы (об этом свидетельствует, например, соотношение рецепторов и ганглиозных клеток в сетчатке – 125:1); конвергенция – основной механизм обработки активности нейронов нервных центров. Для темы же настоящей работы важен, кроме того, факт наличия в сетчатке «прямого пути», который, как предполагает Д. Хьюбел [1], обеспечивает высокую остроту зрения. В «прямом пути» одна биполярная клетка связана с одним рецептором, а одна ганглиозная с одной биполярной.* Здесь, в работе мы допускаем, что «прямым путем» связано с сетчаткой (опосредованно через НКТ) поле V 7 зрительной коры (см. (3), (9)) – возможно, это необходимо системе внимания для точной идентификации принадлежности поступающей актуальной активности тем точкам РЗП, в которые она направляла взор.

(*9) Схема процесса восприятия (рис. 2), – согласно вышеизложенным фактам и представлениям.* Из актуально (см. (6)) активированных афферентных нейронов система внимания (СВ) выбирает** таковые, «достойные её внимания» (например, пул № 5), и активирует соответствующий*** им пул мотонейронов (№5); мотонейроны пула № 5 активируют соответствующий им пул (№ 5) мышц глаза; мышцы, поворачивая глазное яблоко, направляют «луч» взора (№ 5) в соответствующий ему пул точек (№ 5) РЗП. Активность от этого пула поступает (через сетчатку и НКТ) на соответствующий ей пул (№ 5) афферентных нейронов в поле коры V 7 (возможно, здесь по «прямому пути»; см. (8)); остальные нейроны V 7 получают активность тоже от соответствующих им точек РЗП – благодаря механизму константного экрана (см. [6]). В афферентные поля V1, V2, … поступает активность по ретинотопическим (см. (2)) путям. Вся поступившая («от данного взора») активность обрабатывается одновременно во всех афферентных полях; её результаты используются СВ для запуска нового цикла; он начинается новой саккадой, переводящей взор в новую точку РЗП.

---

* Это, тем не менее, не значит, что имеет место связь 1:1 рецепторов и афферентных нейронов – ибо, в качестве единицы (точки или нейрона) выступает, как правило, некоторое их количество (пул из них); следует учитывать также их организацию в виде рецептивных полей.

** Теоретически, механизма выбора поддается моделированию.

*** Механизм этого соответствия требует отдельного анализа.

(10) Краткие обобщающие замечания (вместо обсуждения). 1) В предложенной работе не обсуждается вопрос, что представляет собой СЗО с физической точки зрения; этому дискуссионному вопросу посвящены (в основном и в частности) большие работы авторов, упомянутых уже во Введении – [2, 3, 5]. Здесь лишь отметим, что вывод в ней, – что единственным экраном, на котором реализуются ТК точек РЗП является само РЗП, – дополнительно аргументирует заключение в работе [4], закрывающее психофизиологическую проблему «гомункулуса». 2) Схема на рис. 2 достаточна (в принципе) для осуществления **зрительного поведения** субъекта (и/или робота). В то же время, остается неизвестным компонент, которого в ней недостаёт, для осуществления феномена, определяемого как «интеграция активности афферентной и эфферентной систем в **СЗО**». 3) Предваряющее знание в системе внимания ТК точек РЗП, от которых она получает афферентную активность (см. (6), содержит момент предсказательности; кроме того, получаемая активность от точек РЗП «наслаивается» **на уже имеющийся** (как бы предсказываемый) в системе внимания **паттерн активности**. В этих моментах видится аналогия с процессами, которые именуются в работах П.К. Анохина [17] как «предсказываемое будущее» и «приём обратной афферентации».

Выводы

1) Точные координаты (ТК) точек реального зрительного пространства (РЗП) «задаются» самой зрительной системой; они репрезентированы только её эфферентной частью − мотонейронами и глазодвигательным аппаратом.

2) Глазодвигательный аппарат выступает как полярная система координат, представленная в физическом («макетном») виде.

3) Экраном, на котором реализуются ТК точек РЗП, является само РЗП.

Список литературы

1. Хьюбел Д. Глаз, мозг, зрение. М.: Мир, 1990. 239 с.

2. Пенроуз Р. Тени разума: в поисках науки о сознании. Ч. I: Понимание разума и новая физика. М.-Ижевск: Институт компьютерных исследований, 2003. 368 с.

3. Соколов Е.Н. Очерки по психофизиологии сознания. М.: МГУ, 2008. 255 с.

4. Рамачандран В.С. Мозг рассказывает. Что делает нас людьми. М.: Карьера Пресс, 2012. 422 с

5. Чалмерс Д. Сознающий ум: В поисках фундаментальной теории. М.: УРСС, Книжный дом «ЛИБРОКОМ», 2015. 512 с.

6. Воронков Г. С. Изотов В.А. Нейронный механизм константного экрана. XXII Международная научно-техническая конференция «Нейроинформатика-2020»: Сборник научных трудов. М.: НИЯУ МИФИ, 2020. С. 112–119.

7. Воронков Г.С. Неизвестная характеристика феномена «Куб Неккера»: два 3D образа куба зеркальны друг другу. XXIV Международная научно-техническая конференция «Нейроинформатика-2022»: Сборник научных трудов. М.: МФТИ, 2022. С. 333–342

8. Воронков Г.С. Почему тени, создающие пятно «специфического дефицита зрения», не проявляются в обычных условиях видения: аналогия со «слепым пятном». XX Международная научно-техническая конференция «Нейроинформатика-2018»: Сборник научных трудов. В 2-х ч. Ч. 1. М.: НИЯУ МИФИ, 2018. С. 193–201.

9. Воронков Г.С., Модельный подход как новая парадигма в теории связи в сенсорных системах // Вестн. Моск. ун-та. Сер. 16. Биология. 1993, вып. 1. С. 3–10.

10. Воронков Г.С. Понятия «модель» и «соответствие»: нейрофизиологический и общий аспекты // Философия и будущее цивилизации. Тезисы докл. и выст. IV Российского философского конгресса. Том. 1. М.: Современные тетради, 2005. С. 707–708.

11. Воронков Г.С. Понятие «модель» в нейрофизиологическом модельном подходе // Материалы XVI Международной конференции по нейрокибернетике. Т. 2. Ростов-на-Дону. Издательство ЮФУ. 2012. С. 85–88.

12. Воронков Г.С. Фактор зеркальности в зрении и мышлении: морфологические и функциональные проявления. XXIII Международная научно-техническая конференция «Нейроинформатика-2021»: Сборник научных трудов. М.: НИЯУ МИФИ, 2021. С. 78–87.

13. Супин А.Я. Нейрофизиология зрения млекопитающих. М..: Наука, 1981. 252 с.

14. Воронков Г.С. Инверсия сетчатки и перекресты зрительных волокон как нейроанатомические механизмы зеркальных преобразований. // Вестник московского университета. Серия 16. Биология. 2009, № 4. С. 8–13.

15. Логвиненко А.Д. Зрительное восприятие пространства. М.: Изд-во Моск. ун-та, 1981. 224 с.

16. Ярбус А.Л. Роль движений глаз в процессе зрения. М.: Наука, 1965. 166 с.

17. Анохин П.К. Очерки по физиологии функциональных систем. М.: Медицина, 1975. 448 с.

И.В. СЫСОЕВ[1,2], М.В. КОРНИЛОВ[1,2], Н.М. ЕГОРОВ[1,3], М.В. СЫСОЕВА[1,3]

[1]Саратовский филиал Института радиотехники и электроники им. В. А. Котельникова Российской академии наук

[2]Саратовский национальный исследовательский государственный университет имени Н. Г. Чернышевского

[3]Саратовский технический университет имени Гагарина Ю. А.

dr.ilya.sysoev@yandex.ru

МАТЕМАТИЧЕСКАЯ И РАДИОФИЗИЧЕСКАЯ МОДЕЛИ ГЕНЕРАТОРА ОСНОВНОГО РИТМА ЛИМБИЧЕСКОЙ ЭПИЛЕПСИИ[1]

Лимбическая эпилепсия – наиболее распространённая форма заболевания, которой часто сопутствуют судороги. Источник патологической активности – это очень маленькая сеть нейронов где-то в гиппокампе. Вопросы о том, как устроена эта сеть, каков физический механизм возникновения колебаний в ней, как происходят модуляция и перестройка частоты – пока плохо изучены из-за сложности доступа к предмету исследования. В данной работе нами предложена простая модель в виде кольца связанных пирамидных нейронов, позволяющая реализовать в численном и натурном радиофизическом эксперименте генератор основного ритма с перестраиваемой частотой. Показано, что такая простая система устойчива к возмущениям параметров нейронов и структуры связей, а также может обеспечить перестройку основной частоты генерации, наблюдаемую экспериментально.

Ключевые слова: *эпилепсия, генератор основного ритма, кольцевой генератор, математическая модель нейрона, радиофизическая модель нейрона.*

Введение

Лимбическая эпилепсия – наиболее распространённая форма заболевания, которой часто сопутствуют судороги [1; 2]. Предлагается, что источник патологической активности (основной генератор ритма) находится

[1] Работа выполнена при поддержке Российского научного фонда, грант № 19-72-10030-П, https://rscf.ru/project/19-72-10030/.

в гиппокапме одного из полушарий и представляет собою крошечную область или сеть [3] – эпилептическом фокусе. Эта область или сеть затем синхронизует иные, окружающие области гиппокампа, затем патологическая активность распространяется в энторинальную кору, а из неё – в лобную. Сложные механизмы возникновения и распространения лимбической активности, плохая доступность фокуса для прямого измерения, нестационарность сигналов во время приступов по спектральному составу, амплитуде и форме колебаний, сильная изменчивость приступов (отсутствие повторяемости не только между субъектами, но даже и у одного и того же субъекта) приводят к тому, что адекватные математические модели эпилептиформной активности лимбической эпилепсии до сих пор не построены.

Один из способов решения проблемы – разделить задачи моделирования основного ритма, образующегося в фокальной области гиппокампа, и его дальнейшего распространения (генерализации). В данной работе сделан первый шаг на этом пути – предлагается математическая модель основного ритма лимбической эпилепсии в виде кольцевого генератора с перестраиваемой частотою. Было показано, что период генерации зависит от числа элементов в сети и запаздывания между ними. Чтобы оценить структурную устойчивость режимов построенного генератора, нами была сконструирована его радиотехническая реализация.

Математическая модель генератора

В качестве основной модели для отдельного нейрона взята модель Ходжкина–Хаксли [4] – (1) с параметрами, взятыми из работы [5]: $C = 1$ мФ/см^2, $g_{Na} = 40$ мС/см^2, $g_K = 35$ мС/см^2 и $g_L = 0{,}3$ мС/см^2, $V_{Na} = 55$ мВ, $V_K = -77$ мВ, $V_L = -65$ мВ.

$$\begin{aligned}
\frac{dV_i}{dt} &= [I_{stim} - g_{Na} m_i^3 h_i (V_i - V_{Na}) - \\
&\quad - g_K n^4 (V_i - V_K) - g_L (V_i - V_L) + k_i]/C\,, \\
\frac{dm_i}{dt} &= \alpha_m(V_i)(1 - m_i) - \beta_m(V_i) m_i, \\
\frac{dn_i}{dt} &= \alpha_n(V_i)(1 - n_i) - \beta_n(V_i) n_i, \\
\frac{dh_i}{dt} &= \alpha_h(V_i)(1 - h_i) - \beta_h(V_i) h_i,
\end{aligned} \tag{1}$$

где функции α_i и β_p ($p \in \{n, m, h\}$) приведены далее – (2). Параметры отдельных нейронов соответствовали неколебательному (возбудимому) режиму, поскольку именно такой режим характерен для отдельных нейронов гиппокампа (в нём в нормальном состоянии нет нейронов–пейсмейкеров).

$$\begin{aligned} \alpha_n(V) &= \frac{0{,}8(V-25)}{1-e^{-(V-25)/9}}, \quad \beta_n(V) = \frac{-0{,}002(V-25)}{1-e^{-(V-25)/9}}, \\ \alpha_m(V) &= \frac{0{,}182(V+35)}{1-e^{-(V+35)/9}}, \quad \beta_n(V) = \frac{-0{,}124(V+35)}{1-e^{-(V+35)/9}}, \\ \alpha_h(V) &= 0{,}25e^{-(V+90)/12}, \quad \beta_n(V) = \frac{-0{,}25e^{-(V+62)/6}}{e^{(V+90)/12}}, \end{aligned} \tag{2}$$

Все нейроны были соединены в кольцо с однонаправленными связями, как показано на рис. 1, *a*. Общее число нейронов в кольце обозначено как D (на рис. 1, *a*) $D = 10$). Генератор как динамическая система при заданных параметрах находился в бистабильном режиме: кроме устойчивого положения равновесия (режим без колебаний), унаследованного от отдельных нейронов, в нём также возможна коллективная регулярная динамика в виде пробегания импульса по кольцу. Для перехода между режимами (возбуждения колебаний) использовался дополнительный нейрон (в приведённом случае – 11-й), находившийся в колебательном режиме: с него на прочие нейроны приходили несколько импульсов, после чего связь отключалась до конца эксперимента.

a

b

Рис. 1. Схема кольцевого генератора, где каждый элемент представляет собою нейрон (1) (*a*), зависимость частоты генерации от числа элементов в кольце D и времени запаздывания между ними τ (*b*)

Результаты математического моделирования

Численное моделирование проводилось для четырёх различных значений коэффициента связи: $k = 30$, $k = 40$, $k = 50$ и $k = 60$. Для каждого значения коэффициента связи рассматривались значения D от 10 до 100 включительно с шагом 5 и значения времени запаздывания в связях $\tau \in [0{,}2; 1{,}0]$ мс с шагом 0,05 мс. Для каждой комбинации k, D и τ получался колебательный режим, в котором определялись период колебаний $T(D, \tau, k)$, по которому далее рассчитывалась частота колебаний $f(D, \tau, k) = 1/T(D, \tau, k)$. Двумерная зависимость частоты колебаний от числа элементов в кольце и величины запаздывания при фиксированном $k = 40$ представлена на рис. 1, *b*. Визуально можно отметить, что зависимость близка к обратной как по D, так и по τ, при этом для малых τ возникновение колебаний может быть недостижимо.

Чтобы определить общность полученных в численном эксперименте результатов, было решено построить их аналитическую аппроксимацию. Строить такую зависимость проще для периода, а не для частоты, поскольку в таком случае зависимость $T(D, \tau, k)$ можно рассматривать как линейную. Для аппроксимации была использована формула

$$\tilde{T}(D, \tau, k) = T_0(k) + \gamma(k)\tau D + \varepsilon(k)D, \tag{3}$$

где $\tilde{T}$ – теоретическая оценка периода генерации, $\gamma(k)$ – безразмерный параметр, характеризующий вклад каждого синапса в период колебаний, $\varepsilon(k)$ – инерционность (в миллисекундах) отдельного нейрона, $T_0(k)$ – постоянное слагаемое (в миллисекундах), характеризующее общую инерционность контура и не зависящее от числа элементов и запаздывания в нём. Значения $T_0(k)$, $\gamma(k)$ и $\varepsilon(k)$ оценивались для каждого значения k отдельно, в результате было получено 4 набора параметров. Для $k = 40$ были получены следующие значения: $T = 13.49$ мс, $\gamma = 0.960$, $\varepsilon = 2.00$ мс, среднеквадратичная, номированная на среднее значение периода T ошибка аппроксимации составила $\sigma_{40}^2 = 6.4 \cdot 10^{-4}$,что показывает высокий уровень соответствия между численными расчётами и формулой (3).

Радиофизическая модель

Радиофизическое моделирование – один из способов проверить результаты математического моделирования на устойчивость. В натурном эксперименте все элементы неидеальны и неидентичны, тепловые эффекты при-

водят к изменению параметров модели во времени. Всё это должно разрушить «хрупкие», физически не реализуемые режимы, возможные в математических моделях. Таким образом можно до определённой степени проверить реалистичность модельных представлений: если они не могут быть реализованы в радиофизической модели, то и в биологической системе они, скорее всего, невозможны. Помимо прочего, радиофизическое моделирование предоставляет реалистичные условия измерения: присутствуют шумы, конечное разрешение АЦП как по числу уровней квантования, так и по частоте выборки, часто – смещение постоянного потенциала и масштабный коэффициент.

Поскольку реализация модельных нейронов Ходжкина–Хаксли в натурном эксперименте крайне сложна из-за сложности нелинейных функций (2), в качестве узлов модели была использована радиотехническая модель отдельного нейрона из работы [6] и синапса с запаздыванием из [7]. В SPICE симуляторе Multisim реализована схема генератора из 7–25 нейронов ФитцХью–Нагумо [8; 9], повторяющая схему на рис. 1, *a*. Полученные зависимости частоты *f* от числа нейронов *D* и времени запаздывания τ представлены на рис. 2, *a*.

Рис. 2. Зависимость частоты колебаний в кольце от числа нейронов *D* и времени запаздывания в синапсе τ: *a* – для модели, выполненной в симуляторе электрических схем, *b* – для экспериментальной модели

Видно, что результаты математического моделирования качественно повторяются: зависимость $f(D, \tau)$ – гиперболическая. При этом есть и существенные отличия. Во-первых, абсолютные значения частоты на порядок выше. Это связано со спецификою радиофизической модели: получение в ней колебаний на низких частотах порядка единиц герц требует нестандартных компонентов, поэтому для упрощения моделирования и без

потери общности практически всегда вводят масштабный коэффициент по времени, как это делалось ранее. Во-вторых, присутствует большое число пар значений (D, τ) в левом нижнем углу, соответствующих малым суммарным запаздываниям, при которых колебания в кольце не реализуются, есть единственный аттрактор – устойчивая точка. В-третьих, для $\tau \geq 0{,}3$ мс имеются режимы с удвоенною частотою. Эти режимы легко объяснить теоретически: при очень малой длине кольца импульс затухает, так как возвращаясь к первому нейрону он не может его возбудить вновь из-за гиперполяризации. При достаточной длине кольца потенциал сгенерировавших нейронов может возвращаться к равновесному состоянию не за время, равное половине времени распространения по кольцу или менее. Тогда, если внешнее воздействие работает достаточно долго, оно возбудит первый нейрон ещё раз до того, как импульс вернётся к нему и в кольце будут распространяться два импульса одновременно в противофазе.

В физическом эксперименте мы ограничились $D = 15$ из-за роста стоимости и сложности монтажа. Сопоставление результатов рис. 2, *a* и рис. 2, *b* показывает, что они в целом очень похожи. При этом обнаружить в эксперименте генерацию на двойной частоте нам не удалось: вероятно, при выбранных D и τ этот режим неустойчив. Аппроксимация графика рис. 2, *b* с помощью формулы (3) даёт среднеквадратичную нормированную ошибку аппроксимации $\sigma^2_{exp} = 0.019$, что с одной стороны существенно выше, чем в математической модели, но с другой стороны всё же приемлемо, учитывая неидеальность и неидентичность компонентов схемы.

Заключение

Задача моделирования лимбической эпилепсии в целом далека от решения. Существующие модели отдельных кортикальных колонок [10] и структур гиппокампа [11] не дают ответа на вопрос, как зарождается эпилептиформная активность – что конкретно представляют собою микроконтуры, обнаруженные экспериментально [3], как она распространяется внутри гиппокампа и за его пределы через энторинальную кору. Поскольку лимбическая эпилепсия – многостадийное явление, можно начать моделирование с самого простого – с генератора ритма, который действительно может состоять всего из нескольких нейронов, что и было сделано в данной работе.

В работе нам сначала в математической модели с использованием модельных нейронов Хождкина–Хаксли удалось показать, что небольшое кольцо может демонстрировать колебательный режим при том, что каждый отдельный нейрон находится в возбудимом состоянии. При этом частотою

колебаний можно управлять как с помощью изменения времён запаздывания в синапсах, чему в мозге соответствует изменение концентрации нейромедиаторов, так и с помощью перестройки кольца. Частота (период) при этом подчиняется достаточно простой формуле (3) всего с тремя эмпирическими параметрами, то есть при заданном коэффициенте связей определить частоту колебаний несложно, достаточно произвести всего три измерения. Далее, сначала в симуляторе электронных схем, а затем уже и в натурном эксперименте удалось качественно воспроизвести те же результаты, что и в математическом моделировании, но с использованием схемотехнических реализаций более простых моделей нейронов – нейронов ФитцХью–Нагумо. Таким образом, было продемонстрировано, что предлагаемая схема генерации основной частоты – структурно устойчивая, грубая модель, а значит, она может реализовываться и в биологическом эксперименте.

Список литературы

1. Bertram E. H. Functional Anatomy of Spontaneous Seizures in a Rat Model of Limbic Epilepsy // Epilepsia. 1997. Vol. 38, no. 1. P. 95–105. DOI: 10.1111/j.1528-1157.1997.tb01083.x.

2. Spencer S. S. Neural Networks in Human Epilepsy: Evidence of and Implications for Treatment // Epilepsia. 2002. Vol. 43, no. 3. P. 219–227. DOI: 10.1046/j.1528-1157.2002.26901.x.

3. Paz J. T., Huguenard J. R. Microcircuits and their interactions in epilepsy: is the focus out of focus? // Nature Neuroscience. 2015. Vol. 18. P. 351–359. DOI: 10.1038/nn.3950.

4. Hodgkin A., Huxley A. A quantitative description of membrane current and its application to conduction and excitation in nerve // J. Physiol. 1952. Vol. 117. P. 500–544. DOI: 10.1113/jphysiol.1952.sp004764.

5. Talukdar S., Shrivastava R., Ghosh S. Modeling activity-dependent reduction in after hyper-polarization with Hodgkin-Huxley equation of action potential // Biomedical Physics & Engineering Express. 2019. Vol. 5, no. 4. P.047001. DOI: 10 . 1088 / 2057 - 1976/ab1a1d.

6. Egorov N. M., Sysoev I. V., Ponomarenko V. I., Sysoeva M. V. Complex regimes in electronic neuron-like oscillators with sigmoid coupling // Chaos, Solitons & Fractals. 2022. Vol. 160. P. 112171. DOI: 10.1016/j.chaos.2022.112171.

7. Егоров Н. М., Сысоева М. В., Пономаренко В. И., Корнилов М. В., В. С. И. Кольцевой генератор нейроподобной активности с перестраиваемой частотой // Известия вузов. ПНД. 2023. Т. 31, № 1. С. 103–120. DOI: 10.18500/0869-6632-003025.

8. FitzHugh R. Mathematical models of threshold phenomena in the nerve membrane // Bull. Math. Biophysics. 1955. Vol. 17. P. 257–269. DOI: 10.1007/BF02477753.

9. Nagumo J., Arimoto S., Yoshizawa S. An active pulse transmission line simulating nerve axon // Proc. IRE. 1962. Vol. 50. P. 2061–2070. DOI: 10.1109/JRPROC.1962.288235.

10. Jansen B. H., Rit V. G. Electroencephalogram and visual evoked potential generation in a mathematical model of coupled cortical columns // Biological cybernetics. 1995. Vol. 73, no. 4. P. 357–366. DOI: 10.1007/bf00199471.

11. Meshulam L., Gauthier J. L., Brody C. D., Tank D. W., Bialek W. Collective behavior of place and non-place neurons in the hippocampal network // Neuron. 2017. Vol. 96, no. 5. P. 1178–1191. DOI: 10.1016/j.neuron.2017.10.027.

А.С. РАТУШНЯК, А.Л. ПРОСКУРА,
С.О. ВЕЧКАПОВА, Р.Р. ХУСАИНОВ
Федеральный исследовательский центр
информационных и вычислительных технологий, Новосибирск
ratushniak.alex@gmail.com

ПРИНЦИПЫ МОДЕЛИРОВАНИЯ ВОЗНИКНОВЕНИЯ И ЭВОЛЮЦИИ НЕГЭНТРОПИЙНЫХ ИНФОРМАЦИОННЫХ СИСТЕМ*

Рассматривается задача разработки принципов моделирования молекулярных комплексов, обладающих функцией присущей живому, способностью сохранения комплексной энтропии. На основе концепции поддержания устойчивости при замыкании петли обратной связи агента с внешней средой разработана структура, алгоритм и код модели негэнтропийной информационной системы. Учитывалось, что реакция системы на внешние факторы определяется не только наличием раздражителей, но и прежними воздействиями, т.е. памятью и опережающим отражением.

Ключевые слова: *модели когнитивных функциональных систем, супрамолекулярные логические комплексы, возникновение живых систем, негэнтропия, биоинформатика.*

Введение

При моделировании негэнтропийных систем (НС) нужно исходить из предположения, что они являются цифровыми логическими устройствами,

* Данная работа выполнена при поддержке гранта № 122010800028-4 (ЕГИСУ).

обладающими прогностической функцией, на базе информации, полученной при взаимодействии с окружающей средой. При моделировании необходимо учитывать неупрощаемую сложностью этих систем. Внутренняя молекулярная машина самых простейших из существующих сейчас одноклеточных организмов не может быть смоделирована без существенных упрощений. При этом такие упрощения, как правило, ведут к получению недостаточно функционально и прогностически валидных результатов.

Существующие проблемы моделирования функциональных биосистем привели к попыткам создания их концептуальных, феноменологических и имитационных моделей [1–5 и др.]. Применяемые математические методы, как правило, не учитывают, цифровой, логический характер работы НС. Молекулы, составляющие основу таких систем, могут находиться в ограниченном числе устойчивых состояний. Однако традиционные подходы к моделированию процессов в биосистемах, в большинстве случаев, базируются на математических методах, ориентированных на непрерывные процессы, сводящиеся к дифференциальным и интегральным уравнениям. Учитывая дискретность НС их моделирование, вероятно, наиболее продуктивно вести с использованием математического аппарата, применимого для дискретных моделей, таких как логические модели, вероятностные булевы сети, сети Петри, цепи Маркова, агентные модели и т.д. Создание алгоритмов работы НС имеет существенные количественные ограничения, обусловленные, кроме неупрощаемой сложности, их принципиальным параллелизмом. Все это, практически, не позволяет с использованием существующих технологий, достичь результата за астрономически обозримое время [например, 6–8].

В связи перечисленными проблемами представляется целесообразным создание модели, предельно простых супрамолекулярных конструкций, которые флуктуационно формировались в период возникновения живых НС и, вероятно, существуют сейчас в составе более сложных многоуровневых комплексов в клетках. Эти системы должны были обладать первичными признаками живого. Как термодинамически открытые системы обладать способностью сохранять или увеличивать комплексную негэнтропию (рис. 1). Формироваться такие молекулярные комплексы могли с некоторым запасом негэнтропии.

Эволюционное преимущество в виде возможности накопления негэнтропии (энергии, информации, структурной упорядоченности) позволяло продолжительное существование в среде с определенным набором факторов. В дальнейшем из таких эволюционно удачных супрамолекулярных конструкций строились, вероятно, более сложные многоуровневые си-

стемы (уровня одноклеточных), что позволяло расширить нишу их возможного существования.

Рис 1. Вариант эскизной схемы простейшего протобиологического агента с элементами молекулярных структур, выполняющих логические операции. Агент состоит из рецепторного блока (R1, R2), блока логических операций и памяти (элементы логики – & («И»), 1 («ИЛИ»), Т – триггер - элемент памяти) и эффекторов – Э – (Ef)

Постановка задачи и описание алгоритма

При анализе предпосылок возникновения негэнтропийных (биологических) систем необходимо исходить из возможных условий их спонтанного формирования. В эти условия входят наличие необходимых молекулярных компонентов, взаимодействующих с достаточно значимой вероятностью, нескольких взаимосвязанных процессов (факторов) и энергоинформационного градиента. Возникающие конструкции, взаимодействуя с окружающей средой, должны выполнять базовые функции, присущей живому, к которым относятся способности сохранять устойчивость организации системы при замыкании петли обратной связи организма с внешним миром [9, 10]. При этом необходимо учитывать, что реакция системы на внешние факторы зависит не только от наличия раздражителей, но и от прежних воздействий [3, 11–13], т.е. от памяти и опережающего отражения. Роль компонентов, из которых, вероятно, спонтанно формировались разнообразные конструкции выполняли достаточно простые молекулы, присутствующие в

среде и способные выполнять функции логических элементов [11, 12]. Из таких элементов могли возникать молекулярные конструкции с некоторым запасом устойчивости (негэнтропии) при взаимодействии с факторами среды “определяющие” (и запоминающие) взаимосвязь внешних воздействий и обладающие эффектором, обеспечивающим реагирование [11–15].

В данной работе предпринята попытка разработки модели возникновения простейших негэнтропийных биосистем. Разработаны варианты алгоритмов (рис. 2) и реализован программный код.

Рис. 2. Эскизный вариант алгоритма функционирования агента в среде с двумя факторами. Объяснения в тексте

Агент – это объединённый набор элементов, которые благодаря взаимодействию друг с другом, приобретает дополнительные функции (свойства). В эти свойства входит возможность выполнять простейшие логические операции – определения взаимосвязанности событий, их запоминания, прогноза на основе предыдущего «опыта» и реагирования, опережающего сами события во внешней среде. Таким образом, Агент соответствует базовой функции протобиологической системы.

Структура каждого Агента следующая:

Агент на старте имеет «Стартовое количество энергии» L, которое не может превышать задаваемый максимум. У Агента имеются структурные

элементы, выполняющие роль рецепторов, которыми он считывает приходящие события, формируя сигнал. После того, как сигнал считается, он будет обработан элементами, посредством простейших логических операций И, ИЛИ и памяти. Затем, после обработки срабатывает эффектор (Ef). Агент приобретает некоторое количество энергии (nL). При этом если L превышает заданный порог, то происходит увеличение вероятности появления взаимосвязанных сигналов.

Разработана программа, функционирующая по следующему алгоритму:

1. Старт. {Переход на п. 2–5}

На старте происходит формирование Агента, который после воздействия сигналов f и F запоминает какие сигналы были и при повторе последовательности реагирует с меньшими потерями.

2. Формирование Агента с вероятностью p и с запасом жизни L. {Переход на п. 6}

3. Формирование сигнала F с вероятностью pF. {Переход на п. 6}

Сигнал f – Не значительно увеличивающий энтропию и вычитание из L за реакцию от него небольшое, однако, его вполне достаточно, чтобы Агент зафиксировал это воздействие и после nf (предшествующих nF) вызывал срабатывание эффектора. При этом исключается потеря негэнтропии и/или приобретение дополнительной L.

4. Формирование сигнала f с вероятностью pf. {Переход на п. 6}

Сигнал F – следующий за сигналом-f вызывает значительную потерю L (величина задается исходно).

5. Формирование взаимосвязанных сигналов f->F с вероятностью p f->F. {Переход на п. 6}

При этом, сигналы не обязательно должны быть связаны причинно-следственно. Такая связанность определяется в дальнейшем по соотношению вероятностей формирования, связанных f->F и не ассоциированных f и F сигналов. Если сигналы не имеют причинно-следственной связи, Агент удаляет из памяти данные о их связанности.

6. Агент с запасом L. {Переход на п. 7–9}

На старте происходит формирование Агента, который после воздействия сигналов f и F запоминает какие сигналы были и при повторе последовательности реагирует с меньшими потерями, в противном случае, данный Агент, теряя L до задаваемого предела – деактивируется. Переход на новый цикл

7. FL=L-L*xF. {Переход на п. 10}

8. fL=L-L*xf. {Переход на п. 11}

После реализации последовательности сигналов создаётся набор Агентов в задаваемом количестве «Количество Агентов на старте».

9. F -> L=L-L*(xF+xf). {Переход на п. 12}

Перед циклом происходит проверка на то, есть ли живые Агенты или нет.

10. L>0. {Если «ДА», то переход на п. 13, если «НЕТ», то переход на п. 2}

11. L>0. {Если «ДА», то переход на п. 14, если «НЕТ», то переход на п. 2}

12. L>0. {Если «ДА», то переход на п. 15, если «НЕТ», то переход на п. 2}

Если живых Агентов нет, то программа завершается, выводя окончательный результат за все итерации циклов, если нет – продолжается выполнение программы.

13. Fz – количество циклов. {Переход на п. 13}

14. fz – количество циклов. {Переход на п. 14}

15. z – количество циклов. {Переход на п. 15}

После новых сигналов, происходит дополнительная проверка Агентов на выживаемость. Если есть живые Агенты, то цикл повторяется до тех пор, пока не останется ни одного живого Агента или же не дойдёт до установленного максимального количества циклов.

16. FZ≥FZn. (где Zn - количество повторов xf->F до запоминания ассоциации (F->f=E), E – эффектор) {Если «ДА», то переход на п. 22, если «НЕТ», то переход на п. 19}

Эффектор получает сигналы с временными метками. Каждый полученный сигнал запоминается как последний.

17. fZ≥fZn. {Если «ДА», то переход на п. 23, если «НЕТ», то переход на п. 20}

18. Z≥Zn. {Если «ДА», то переход на п. 24, если «НЕТ», то переход на п. 21}

Если полученный сигнал – F, а последний полученный (перед этим) – f, то сравниваются временные метки сигналов. Если они отличаются меньше, чем на «Допустимая погрешность прогноза», то Агент получает L в задаваемом размере.

19. L>0. {Если «ДА», то переход на п. 3, если «НЕТ», то переход на п. 2}

20. L>0. {Если «ДА», то переход на п. 4, если «НЕТ», то переход на п. 2}

21. L>0. {Если «ДА», то переход на п. 5, если «НЕТ», то переход на п. 2}

22. L=L-L*xF. {Переход на п. 25}

23. L=L-L*xf. {Переход на п. 26}

24. L=kL, Срабатывание Э. (где k – соотношение количества ассоциированных и неассоциированных F и f, R – коэффициент умножения N при F->f=E {Переход на п. 27}

25. L>0. {Если «ДА», то переход на п. 2, если «НЕТ», то переход на п. 3}

26. L>0. {Если «ДА», то переход на п. 2, если «НЕТ», то переход на п. 4}

27. L>zL. {Если «ДА», то переход на п. 28, если «НЕТ», то переход на п. 5}

По ходу выполнения алгоритма, программой каждый сигнал отправляется одновременно всем Агентам. Затем следует обсчёт реакции Агента. Если по завершении суммарная энергия L Агента оказалась равна 0 или меньше, Агент дезактивируется, если же больше 0, то это означает, что Агент после пройденного сигнала выжил.

28. pf->F=pfn->F. (pfn->Fn – вероятность ассоциации сигнала – f и сигнала F. [ассоциированного и неассоциированного сигналов]) {Переход на п. 6}

Если после прохождения n сигналов, Агент выжил, то записывается, что данная комбинация сигналов связана причинно-следственно. Хотя такой, по сути, «статистический» подход к определению причинно-следственных закономерностей не соответствует, вероятно, принципам, работающим биологических когнитивных системах.

Результаты реализации алгоритма

Разработаны модели НС как негэнтропийных биоагентов. Программная реализация алгоритма позволила при интуитивном подборе параметров получить варианты агентов, обладающие способностью сохранения своих параметров неограниченное количество циклов взаимодействия со средой (рис. 3).

Для визуализации результатов программы на данном этапе был выбран линейный график – это простейший способ визуализации данных. У такого подхода к отображению показателей есть много полезных качеств.

Данный график состоит из трёх показателей:

1. Максимальная продолжительность жизни
2. Средняя продолжительность жизни
3. Количество живых Агентов

Как видно из графика (см. рис. 2), отбор агентов средой уменьшает численность популяции. При этом средняя и максимальная продолжительность жизни увеличиваются.

Сигнал-f приходит перед сигналом F, что даёт Агенту возможность «предсказать» развитие процесса F и избегать большей потери негэнтропии. Кроме того, на графике можно заметить, что средняя продолжитель-

ность жизни и максимальная продолжительность жизни имеют разные тенденции изменения во времени. Средняя продолжительность жизни имеет более плавный характер изменения, тогда как максимальная продолжительность жизни имеет более резкие скачки. Это может быть связано с тем, что у некоторых Агентов определились такие вероятностные значения параметров, которые позволяют им жить дольше.

Рис. 3. Пример динамики параметров группы агентов, взаимодействующих со средой

Для ускорения анализа особенностей алгоритма Агента был сделан переход к моделированию их популяции. На графике представлены только данные об одной реализации и популяции Агентов. Результаты могут отличаться в зависимости от заданных параметров среды и Агента. Поэтому для более точного предсказания динамики популяции проводились эксперименты с различными значениями параметров.

В целом, линейный график позволяет наглядно отобразить зависимость между различными показателями и выявить закономерности в изменении этих показателей со временем. Однако для более полного и точного анализа данных, возможно, потребуется использование других типов графиков и методов статистического анализа.

Заключение

Можно предположить, что в составе внутриклеточных сигнальных сетей, кроме известных (рецепции, усиления сигналов и включения эффекторов) присутствуют еще и удачно сформированные в процессе длительной эволюции молекулярные системы обеспечивающие выявления и запоминания ассоциативных воздействий, вызывающие опережающие реакции системы и стабилизирующие, таким образом, гомеостаз. Выявление и инструментальное моделирование многоуровневых негэнтропийных молекулярных конструкций является задачей дальнейшего детального анализа внутриклеточной молекулярной сети, на примере относительно простых сетей в синапсах [16 и др.]. Опираясь на модель биоагента основанную на физических представлениях о базовых функциях биосистем и учитывая преемственность, эмерджéнтность организации таких систем, в дальнейшем представляется возможным попытаться моделировать их эволюцию, наращивая сложность до пределов аппаратных ограничений. Подход к моделированию возникновения и эволюции негэнтропийных информационных систем на базе модели простейшего негэнтропийного агента представляется наиболее перспективным.

Данная работа является развитием исследований [16, 17].

Список литературы

1. Анохин П.К. Основные вопросы теории функциональных систем. Философские аспекты теории функциональных систем // М: Наука. 1978. С. 49–106.
2. Anokhin P.K. Anticipatory reflection of reality // Vopr. Philosophy. 1962. No 6. P. 97–109.
3. Сеченов И.М. Собрание сочинений И. М. Сеченова // ARCHIVE PUBLICA. 2022. 241 с.
4. Tsitolovsky L. Consciousness, endogenous generation of goals and homeostasis // International Journal of General Systems. 2015. V. 44. No 6. P. 655–666.
5. Nakajima T. Biologically inspired information theory: Adaptation through construction of external reality models by living systems // Prog Biophys Mol Biol. 2015. V. 119. No 3. P. 634–648.
6. Goranson T., Cardier B., Devlin K. Pragmatic phenomenological types // Prog Biophys Mol Biol. 2015. V. 119. No 3. P. 420–436.
7. Liao J.C., Boscolo R., Yang Y.L., Tran L.M., Sabatti C., Roychowdhury V.P. Network component analysis: reconstruction of regulatory signals in biological systems // Proc Natl Acad Sci U S A. 2003. V. 100. No 26. P. 15522–15527.
8. Kraus M., Lais P., Wolf B. Structured Biological Modelling: a method for the analysis and simulation of biological systems applied to oscillatory intracellular calcium waves // Biosystems. 1992. V. 27. No 3. P. 145–169.

9. Marijuán P.C., Navarro J., del Moral R. How the living is in the world: An inquiry into the informational choreographies of life // Prog Biophys Mol Biol. 2015. V. 119. No 3. P. 469–480.

10. Guffanti A. Modeling molecular networks: a systems biology approach to gene function // Genome Biol. 2002. V. 3:reports 4031.1

11. Kriete A., Eils R. Computational Systems Biology // Cambridge: Elsevier Academic Press. 2006. 424 p.

12. Kitano H. Systems biology: A brief overview // Science. 2002. V. 295. No 5560. P. 1662–1664.

13. Schrödinger E. What is life? The physical aspect of the living cell // Cambridge: University Press. 1944. 214 p.

14. Finkelstein A., Hetherington J., Li L., Margoninski O., Saffrey P., Seymour R., Warner A. Computational challenges of systems biology // Computer. 2004. V. 37. No 5. P. 26–33.

15. Aristov V.V., Buchelnikov A.S., Nechipurenko Yury D. The use of the statistical entropy in some new approaches for the description of biosystems, entropy (Basel) // 2022. V. 24. No 2. P. 172.

16. Proskura A.L., Vechkapova S.O., Ratushnyak A.S. Dopamine and hippocampal synaptic plasticity // Procedia Computer Science. 2020. V. 169. P. 668–672.

17. Ratushnyak A.S., Zapara T.A., Proskura A.L., Sklyarov A.N., Sorokoumov E.D. Analysis of appearances, formation and evolution of biological functional systems // Studies in computational intelligence. 2022. V. 1064. P. 231–237.

А.О. РОГАЧЁВ, О.В. СЫСОЕВА
Научный центр когнитивных исследований,
Научно-технологический университет «Сириус»
aorogachev@gmail.com

ПРИМЕНЕНИЕ ФУНКЦИИ ВРЕМЕННОГО ОТКЛИКА ДЛЯ ИЗУЧЕНИЯ НЕЙРОФИЗИОЛОГИЧЕСКИХ МЕХАНИЗМОВ ВОСПРИЯТИЯ РЕЧИ В ЭКОЛОГИЧЕСКИ ВАЛИДНЫХ УСЛОВИЯХ[1*]

Рассматривается применение функции временного отклика – метода, позволяющего изучать нейрофизиологические механизмы обработки естественных речевых стимулов. В нашем исследовании дети в возрасте от 6 до 8 лет

[1*] Финансирование проекта осуществлялось Министерством науки и высшего образования Российской Федерации (Соглашение № 075-10-2021-093; Проект COG-RND-2262).

прослушивали аудиозаписи детских сказок, одновременно проводилась регистрация электроэнцефалограммы. В результате было показано, что коэффициенты прогнозирования функции временного отклика положительно связаны с уровнем развития понимания речи, обращенной к ребенку.

Ключевые слова: *речь, развитие речи, функция временного отклика, ЭЭГ.*

Введение

Речь – одна из важнейших составляющих жизни человека. При помощи речи человек не только взаимодействует с окружающим миром, но и управляет своим собственным поведением [1]. Разнообразные нарушения речи ведут как к различным нарушениям развития человека, так и к психологическим проблемам, так как речь влияет и на профессиональную, и на личную жизнь [2]. Для своевременной правильной диагностики и последующей коррекции речевых нарушений необходимо понимать не только психологические, но и нейрофизиологические, мозговые механизмы речи.

Одним из традиционных методов изучения нейрофизиологической основы когнитивных процессов человека является электроэнцефалография (ЭЭГ) – неинвазивный метод, позволяющий регистрировать электрическую активность головного мозга с поверхности кожи головы. ЭЭГ регистрируется при выполнении человеком экспериментальных задач, направленных, например, на изучение восприятия, памяти или иных процессов. Часто при анализе ЭЭГ используется метод вызванных потенциалов (ВП). Метод ВП состоит в многократном предъявлении одного и того же стимула. После предобработки ЭЭГ производится усреднение интервалов записи, соответствующих предъявлению стимула. Постоянный мозговой ответ, связанный со стимулом, при усреднении остается, тогда как шум и «посторонний» сигнал минимизируется [3]. При помощи метода ВП получено огромное количество данных по мозговым механизмам различных когнитивных процессов, а также по различиям этих механизмов между разными группами людей. Множество данных получено и в исследованиях речи на различных уровнях – как акустическом и фонологическом [4], так и на более высоком семантическом, касающимся смысловой стороны речи [5].

Несмотря на большое количество данных, в них встречаются противоречия. Возможной причиной этого является особенность самого метода ВП: он требует предъявления изолированных, «идеальных» стимулов – например, отдельных фонем, слов, либо предложений с резко различающимся друг от друга смыслом – тогда как в реальной жизни такие стимулы

встречаются редко или не встречаются вовсе. Это относится к проблеме экологической валидности исследований – отношению между объектами реального мира и их представлениями в экспериментальных условиях [6]. Результаты экспериментов с применением парадигм, обладающих низкой экологической валидностью, могут противоречить друг другу или недостаточно хорошо экстраполироваться на другие экспериментальные условия.

В последние годы в исследованиях речи активно развиваются методы нейронного отслеживания (neural tracking), позволяющих сопоставлять изменения в электромагнитной активности мозга с изменениями «натурального», продолжительного стимула – например, аудиозаписи художественного рассказа или обычной речи людей [7]. В основе нейронного отслеживания лежит методология идентификации систем: по входу системы (стимул) и ее выходу (электрофизиологический сигнал) определяются характеристики самой системы [8].

Наиболее распространенным инструментом для оценки параметров нейронного отслеживания является вычисление функции временного отклика (ФВО; temporal response function) [9; 10]. В основе ФВО лежит уравнение:

$$s(t) * w(t,n) = r(t,n). \quad (1)$$

Здесь $s(t)$ – характеристика стимула в момент времени t, $r(t,n)$ – электрофизиологический ответ (ЭЭГ) в момент времени t по каналу n, а $w(t,n)$ – собственно, значение функции временного отклика в момент времени t по каналу n. ФВО формируется в определенном временном окне (аналогично ВП) – например, в окне от -100 до 500 мс. В этом случае, ФВО на –100 мс будет показывать отношение стимула и ЭЭГ за 100 мс до данного значения времени, а на 500 мс – соответственно, на 500 мс после [11]. Таким образом, характеристики стимула и ЭЭГ можно представить в форме матрицы временных лагов в заданном временном окне.

Вычисление ФВО заключается в минимизации среднеквадратичной ошибки между реальными данными ЭЭГ и данными, предсказанными путем линейной свертки ЭЭГ и ФВО. Это решается при помощи вычисления обратной корреляции, которая заключается в решении следующего уравнения [11]:

$$w = (S^T S + \lambda E)^{-1} * S^T R, \quad (2)$$

$S^T S$ по своей сути является матрицей автоковариации характеристик стимула в заданном временном окне, E – единичная матрица, λ – параметр регуляризации. Поиск оптимального параметра регуляризации – такого, при котором среднеквадратичная ошибка между реальными и предсказанными моделью данными будет минимальной, – производится на этапе кросс-валидации модели [9; 11].

В уравнениях (1) и (2) представлена математическая реализация вычисления прямых (forward) моделей, которые предсказывают выход системы по ее входу (предсказание ЭЭГ по стимулу). При замене местами матриц стимула и ЭЭГ можно рассчитать обратную (backward) модель, которая, напротив, будет предсказывать стимул по данным ЭЭГ. Первый класс моделей также называют кодирующими (encoding models), а второй – декодирующими (decoding models) по их смыслу [9].

После вычисления ФВО доступны два основных показателя для анализа: форма и особенности самой ФВО (распределение коэффициентов линейной модели в заданном временном окне по каждому каналу ЭЭГ для прямой модели и в размерности стимула для обратной модели) и коэффициенты прогнозирования – способность модели предсказывать ЭЭГ по стимулу (либо декодировать стимул из ЭЭГ для обратных моделей), что представляет собой корреляцию между реальными данными ЭЭГ и данными, предсказанными моделью.

Таким образом, путем выполнения операции линейной свертки между стимулом и ЭЭГ можно оценить ответ мозга на изменения характеристик в продолжительном стимуле, в том числе обладающим высокой экологической валидностью [12]. В качестве стимула для ФВО могут выступать как низкоуровневые, акустические характеристики (например, огибающая речевого сигнала), фонологические (временные точки появления отдельных фонем или слов) и семантические (например, семантические различия между словами, измеренные путем корреляции векторов контекстных представлений слов в многомерном семантическом пространстве) [13; 14].

В последние годы увеличивается количество исследований с использованием ФВО. В основном, в «натуральных» экспериментах принимают участие здоровые взрослые люди. Гораздо меньше исследований с участием детей. В связи с этим, интересным представляется изучение нейрофизиологических механизмов развивающейся речи с применением ФВО.

Методы

В исследовании приняли участие 22 ребенка (12 мальчиков, 10 девочек) в возрасте от 6 до 8 лет (средний возраст 6,81 лет, станд. откл. 0,58). Критерием отбора участников в анализ данных были отсутствие выявленной эпилептиформной активности и пройденная оценка уровня развития рецептивной речи, которая осуществлялась при помощи игровой методики Preschool Language Scales версии 5 (PLS-5) [15]. Баллы данной методики располагаются на 100-балльной шкале.

Участники прослушивали три аудиоистории общей длительностью 14 мин, и параллельно смотрели видеоряд для поддержания внимания. При выполнении экспериментальной парадигмы проводилась регистрация 32-канальной ЭЭГ при помощи электроэнцефалографа Brain Products actiCHamp (Brain Products GmbH, Gilching, Germany). Предобработка ЭЭГ включала в себя фильтрацию данных в диапазоне от 1 до 15 Гц, удаление глазодвигательных артефактов при помощи метода независимых компонент (ICA) и переустановка референта записи ЭЭГ на усредненный электрод. Дальнейший анализ осуществлялся при помощи mTRF Toolbox [11] в MATLAB. Временное окно для ФВО было задано в диапазоне от –200 до 600 мс. В качестве стимулов для ФВО были выбраны огибающая речевых сигналов (полученная при помощи преобразования Гильберта; модель 1) и значения семантических различий между словами в тексте, рассчитанными как 1 минус корреляция Пирсона между контекстным вектором данного слова (полученным из модели word2vec [16]) и средним всех векторов предыдущих слов в предложении (модель 2). Для модели 1 по результатам кросс-валидации был выбран оптимальный параметр регуляризации $\lambda = 10^4$, для модели 2 – $\lambda = 1$. Статистический анализ проводился в RStudio.

Результаты

В анализ были включены сырые баллы по шкале восприятия речи (рецептивной речи) PLS-5. Выборка характеризуется средним значением 61,45 (диапазон от 52 до 65, станд. откл. 3,29).

Получены две прямые модели ФВО: на огибающую речевого сигнала (модель 1) и на семантические различия между словами в стимуле (модель 2). Для модели 1 среднее значение коэффициентов прогнозирования, усредненных по всем каналам ЭЭГ, составляет 0,047 (диапазон от 0,015 до 0,074, станд. откл. 0,02); значения значимо отличаются от нуля (односторонний Т-тест Стьюдента: $t(21) = 13{,}683$, $p < 0{,}001$). Для модели 2 среднее значение коэффициентов составляет 0,03 (диапазон от 0,016 до 0,043, станд. откл. 0,009), что также значимо отличается от нуля ($t(21) = 15{,}8$, $p < 0{,}001$) (рис. 1).

Коэффициенты прогнозирования обеих моделей положительно коррелируют с баллами по шкале рецептивной речи PLS-5 (коэффициент корреляции Спирмана): $r(20) = 0{,}49$, $p = 0{,}02$ для модели 1; $r(20) = 0{,}49$, $p = 0{,}02$ для модели 2 (рис. 2). Не выявлено значимой корреляции между коэффициентами прогнозирования моделей и возрастом участников.

Рис. 1. Графики коэффициентов функций временного отклика по всем каналам ЭЭГ для моделей 1 и 2

Рис. 2. Графики коэффициентов прогнозирования ФВО и баллов по шкале рецептивной речи методики PLS-5 для моделей 1 и 2

Обсуждение результатов

Коэффициенты прогнозирования функции временного отклика математически показывают корреляцию между реальной ЭЭГ и ЭЭГ, предсказанной путем линейной свертки ЭЭГ и стимула через ФВО [7; 9; 11], а содержательно – особенности кортикального отслеживания характеристик стимула [12]. В нашей работе показано, что коэффициенты прогнозирования для модели с акустическими и семантическими характеристиками речевых стимулов статистически значимо связаны со способностями детей в возрасте от 6 до 8 лет к пониманию речи, измеренной при помощи методики PLS-5. Предыдущие исследования рассматривали связь коэффициентов прогнозирования ФВО с отдельными психометрическими показателями декодирования фонологических характеристик речи [17], тогда как наше исследование рассматривает такой комплексный процесс, как рецептивная речь. Также, данный метод впервые применен на русскоязычной выборке.

Таким образом, применение ФВО позволяет оценивать способность коры головного мозга к отслеживанию акустического сигнала, а также семантических различий между словами в прослушанном тексте у детей. Также, применение метода предоставляет нейрофизиологические корреляты рецептивной речи. Метод может применяться для психофизиологической оценки уровня развития рецептивной речи у особых клинических групп, характеризующихся трудностями с экспрессивной речью (способностью говорить).

Заключение

Функция временного отклика – новый метод обработки нейрофизиологических данных, позволяющий проводить эксперименты с использованием экологически валидных стимулов и изучать реакции мозга на различные изменения характеристик этих стимулов. В отличие от метода вызванных потенциалов, он дает возможность работать не с изолированными, а с длительными стимулами, и точно так же, как и ВП, рассматривать особенности обработки мозгом различных лингвистических характеристик. Кроме того, ФВО позволяет оценить то, как головной мозг отслеживает стимул.

Наше исследование подтверждает применимость данного метода в исследованиях детской речи. Показано, что параметры ФВО связаны с уровнем развития рецептивной речи – совокупности процессов, связанных с пониманием обращенной к ребенку речи. Данный метод может выступать дополнительным средством оценки уровня развития рецептивной речи, а

также выступать диагностическим инструментом для различных клинических групп, которые характеризуются трудностями в экспрессивной речи или ее отсутствием.

Представленная экспериментальная парадигма является частью исследования, проводимого направлением «Нейробиология устной и письменной речи при расстройствах развития» Научного центра когнитивных исследований Университета «Сириус». Авторы благодарят всех участников исследования и их родителей, а также команду проекта.

Список литературы

1. Выготский Л. С. Мышление и речь // Directmedia. 2014.
2. Dubois P., Pierre M.-C., Desmarais C., Guay F. Young Adults With Developmental Language Disorder: A Systematic Review of Education, Employment, and Independent Living Outcomes // Journal of Speech, Language, and Hearing Research. 2020. Т. 63. № 11. P. 3786–3800.
3. Luck S., Kappenman E. The Oxford Handbook of Event-Related Potential Components // Oxford University Press, 2011. 664 p.
4. Martin B.A., Tremblay K.L., Korczak P. Speech Evoked Potentials: From the Laboratory to the Clinic // Ear and Hearing. 2008. Vol. 29. № 3. P. 285.
5. Kutas M., Federmeier K. D. Thirty Years and Counting: Finding Meaning in the N400 Component of the Event-Related Brain Potential (ERP) // Annual Review of Psychology. 2011. Т. 62. № 1. P. 621–647.
6. Fahmie T.A., Rodriguez N.M., Luczynski K.C., Rahaman J.A., Charles B.M., Zangrillo A.N. Toward an explicit technology of ecological validity // Journal of Applied Behavior Analysis. 2023. Vol. 56. № 2. P. 302–322.
7. Ding N., Simon J.Z. Cortical entrainment to continuous speech: functional roles and interpretations // Front. Hum. Neurosci. 2014. Vol. 8. P. 311.
8. Marmarelis V. Z. Nonlinear dynamic modeling of physiological systems. // John Wiley & Sons. 2004. Т. 10.
9. Crosse M.J., Zuk N.J., Di Liberto G.M., Nidiffer A.R., Molholm S., Lalor E.C. Linear Modeling of Neurophysiological Responses to Speech and Other Continuous Stimuli: Methodological Considerations for Applied Research // Frontiers in Neuroscience. 2021. Т. 15. P. 1350.
10. Lalor E.C., Foxe J.J. Neural responses to uninterrupted natural speech can be extracted with precise temporal resolution // European Journal of Neuroscience. 2010. Vol. 31. № 1. P. 189–193.
11. Crosse M.J., Di Liberto G.M., Bednar A., Lalor E.C. The Multivariate Temporal Response Function (mTRF) Toolbox: A MATLAB Toolbox for Relating Neural Signals to Continuous Stimuli // Frontiers in Human Neuroscience. 2016. Т. 10. P. 604.
12. Alday P.M. M/EEG analysis of naturalistic stories: a review from speech to language processing // Language, cognition and neuroscience. 2019. Т. 34. № 4. P. 457–473.

13. Broderick, M.P., Anderson A.J., Di Liberto G.M., Crosse M.J., Lalor E.C. Electrophysiological Correlates of Semantic Dissimilarity Reflect the Comprehension of Natural, Narrative Speech // Current Biology. 2018. Vol. 28. № 5. P. 803–809.e3.

14. Di Liberto G.M., O'Sullivan J.A., Lalor E.C. Low-Frequency Cortical Entrainment to Speech Reflects Phoneme-Level Processing // Current Biology. 2015. Vol. 25. № 19. P. 2457–2465.

15. Talantseva O.I., An I.O., Zhukova M.A., Trubitsyna A.N., Teedemaa A.V., Grigorenko E.L. Psychometric Properties of the Preschool Language Scales, Fifth Edition (PLS-5) in Russian-Speaking Children: A Classical and Item Response Theory Study // Clinical Psychology & Special Education/Kliniceska I Special'naa Psihologia. 2022. Vol. 11. № 2. P. 174–195.

16. Mikolov T., Sutskever I., Chen K., Corrado G.S., Dean J. Distributed Representations of Words and Phrases and their Compositionality // Advances in Neural Information Processing Systems. 2013. T. 26.

17. Di Liberto G.M., Peter V., Kalashnikova M., Goswami U., Burnham D., Lalor E.C. Atypical cortical entrainment to speech in the right hemisphere underpins phonemic deficits in dyslexia // NeuroImage. 2018. Vol. 175. P. 70–79.

Л.И. БРУСИЛОВСКИЙ[1], А.С. БРЮХОВЕЦКИЙ[2], С.П. КОЖИН[3]

[1]ООО «ЭЛЬБРУС Корпорация», Москва
[2]АО «Клинический госпиталь «Нейровита», Москва
[3]ЗАО «НПП «Исток» им. Шокина
neurovita-as@mail.ru, netsrv@aha.ru

ИССЛЕДОВАНИЯ КОГНИТИВНЫХ МИКРОВОЛНОВЫХ ИЗЛУЧЕНИЙ ГОЛОВНОГО МОЗГА ЧЕЛОВЕКА КАК НОВЫЙ ТИП МИКРОВОЛНОВЫХ ЭНЦЕФАЛОГРАММ

Описываются и анализируются результаты репрезентативного исследования 12-13.07.2021г открытых авторами микроволновых излучений головного мозга человека В УВЧ/СВЧ-диапазоне в зависимости от стимула «свет/темнота» по запатентованной методике регистрации. Краткий статистический анализ амплитудно-частотных характеристик микроволнового электромагнитного излучения подтвердил когнитивный характер программно вычисляемых микроволновых всплесков сигнала над фоном.

Ключевые слова: *высшая нервная деятельность, головной мозг человека, микроволновая энцефалография МВЭГ, нейродиагностика, электромагнитное излучение мозга, микроволновые всплески.*

Введение

С 2016 г. группа ученых-медиков и радиоинженеров инициативным образом проводит исследования по регистрации микроволновых излучений головного мозга человека в УВЧ-/СВЧ-диапазонах**.** В результате были зарегистрированы собственные электромагнитные излучения головного мозга человека в диапазоне от 850 МГц до 5,0 ГГц с мощностью сигналов на уровне -130 дБм −100 дБм (10^{-16} – 10^{-13} Вт), обладающие когнитивными признаками [1]. Методика регистрации была запатентована (патент RU 2708040 C2) [2]. Она легла в основу разработки нового типа неинвазивного исследования головного мозга человека − микроволновой энцефалографии МВЭГ [3, 4].

С 2016 по 2019 г. было проведено 7 серий экспериментальных исследований [5], которые позволили:

1) практически подобрать контрольно-измерительное оборудование (КИО) и подходящие безэховые экранированные камеры (БЭК);

2) разработать и изготовить необходимые компоненты КИО, в том числе внешний малошумящий усилитель (МШУ) 1-1М;

3) разработать, усовершенствовать и неоднократно подтвердить программу-методику регистрации регулярных микроволновых всплесков, отличных от помех и шумов;

4) в широком диапазоне частот от 850 МГц до 26,5 ГГц экспериментально выделить частотный диапазон от 1,0 до 4,5 ГГц, на котором наблюдается микроволновая активность головного мозга человека с мощностью сигналов на уровне –130 .. –100 дБм (10^{-16} – 10^{-13} Вт);

5) обнаружить когнитивные признаки регистрируемых внутренних микроволновых всплесков в зависимости от стимула «свет/темнота».

Постановка задачи

В новом исследовании ставились следующие задачи:

1) еще раз подтвердить внутренний характер микроволновых всплесков головного мозга, зарегистрированных в предыдущих исследованиях 2016-2019 гг.;

2) подтвердить репрезентативными экспериментами когнитивный характер регистрируемых микроволновых всплесков в зависимости от стимула «свет/темнота»;

3) проверить новые доступные инструментальные средства, прежде всего, различные измерительные антенны для регистрации микроволновых всплесков из головного мозга.

Проведение нового исследования 12-13.07.2021

Новое исследование состоялось в «Испытательной лаборатории технических средств по параметрам ЭМС» ФБУ «Ростест-Москва».

В соответствии с запатентованной методикой регистрации собственных микроволновых излучений мозга [2] в качестве измерительного прибора используется анализатор спектра (АС) профессионального класса, который сразу оцифровывает электромагнитный сигнал во временной области и аппаратными средствами быстрых преобразований Фурье (БФП) трансформирует функции времени в функции частоты, содержащие информацию об амплитуде и фазе − амплитудно-частотные характеристики (АЧХ) сигнала. Таким образом, АС − это прибор, который позволяет визуализировать распределение энергии электромагнитной волны по частотам [6].

В описываемом исследовании использовался АС производства Rohde & Schwarz: R&S®ESW премиум-класса с функцией реального времени (РВ). В настоящее время – это лучший АС в мире по характеристикам фазовых шумов, полосе демодуляции и скорости работы. Его чувствительность с учетом теплового шума находится почти на теоретическом пределе при комнатной температуре и улучшить ее можно только за счет охлаждения измерительного прибора и объекта измерения.

Работа в режиме РВ позволяет одновременно собирать, обрабатывать и отображать данные. Аппаратная система параллельного захвата сигналов и их анализ с перекрытием позволяют отображать спектр сигнала без потери данных. Для обнаружения сигнал или событие должно присутствовать в течение по крайней мере одного полного БПФ. Стандартный АС ESW без дополнительных опций регистрирует события с продолжительностью от 1,7 мкс (585 938 БПФ/с).

Все экспериментальные данные в цифровом и графическом виде записывались встроенными средствами регистрации прибора.

Еще одной важной компонентой системы регистрации является измерительная антенна. В исследовании измерения проводились с двумя марками измерительных логопериодических антенн (ИЛА):

1) R&S®HL050 с рабочим диапазоном частот (РДЧ) 0,85..26,5 ГГц с коэффициентом усиления (Кус) 8,5 дБ и с внешним блоком малошумящего усиления (МШУ) 1-1М собственной разработки с Кус=30 дБ в РДЧ 2..4 ГГц (суммарно Кус=38 дБ);

2) П6-222М производства АО СКАРД-Электроникс с РДЧ 1..18 ГГц и Кус в активном режиме 24 дБ.

Для защиты от посторонний шумов и помех исследования проводились в БЭК SAC-3 высшего класса защиты по ГОСТ Р 50414-92 (аттестат ФГУП

НИИФТРИ № 18/ПА-008/12 от 15.03.2012). При исследованиях были предприняты меры защиты от посторонних помех. В рабочем помещении БЭК находился только 1 исследуемый человек, все его личные электронные гаджеты: мобильные телефоны, электронные часы и т.п. были удалены за пределы БЭК. Измерительный приемник был размещен в приборном отсеке вне защищенного рабочего помещения, чтобы исключить влияние собственных эфирных излучений. Встроенный радиочастотный кабель длиной 10м для подключения измерительной антенны проходил через специальный защищенный кабельный канал.

Регистрация велась с правой/левой затылочных областей скальпа головы (соответствует зрительной доле коры головного мозга). Всего было проведено 8 серий экспериментов, которые отличались объектом исследований (голова человека, контрольный образец, фон), типом измерительной антенны, включенного/выключенного МШУ, диапазоном и количеством измерений. Многократное сканирование велось в режиме накопления. Основным стимулом служило включение/выключение света в экранированном помещении БЭК.

Всего было проведено 166 экспериментов: 150 экспериментов на волонтере, 16 на контрольном образце, 10 экспериментов исследования фона.

Основные существенные параметры серий экспериментов сведены в табл. 1.

Эксперименты с участием волонтера не были связаны в каком-либо воздействием на его мозг, а только с высокочувствительным приемом излучения. Волонтер дал письменное согласие и все экспериментальные процедуры с его участием были проведены в соответствии с Хельсинкской декларацией Всемирной медицинской ассоциации 2013 г.

В качестве контрольного образца использовалась 5-литровая пластиковая емкость, заполненная физиологической жидкостью, нагретой до 37 °С. Адекватность модели основывается на том, что источник микроволнового излучения в диапазоне 1,5..4,5 ГГц с учетом диэлектрической проницаемости оболочки головного мозга может находиться на глубине от 1 до 3 см, что включает слой спинномозговой жидкости головного мозга. Глубина источника микроволновых излучений также оценивается при измерении глубинной температуры головного мозга методами пассивной микроволновой радиометрии [7, 8].

В течение всех серий экспериментов независимо регистрировался фон с места проведения эксперимента отдельно для стимула СВЕТ, отдельно для стимула ТЕМНОТА. Программная обработка их АЧХ показала практическое совпадение фонов по существенным всплескам.

Таблица 1

Существенные параметры серий экспериментов

Серия	1	2	3	4	5	6	7	8
Кол-во экспериментов	40	20	20	20	40	10	6	10
Кол-во точек АЧХ	4150	4001	4001	4001	2001	2001	2001	2001
Область головы	Пр. затылок	Пр. затылок	Пр. затылок	Лев. затылок	Пр. затылок	Модель	Модель	Фон
Тип антенны	HL 050	П6-222М	П6-222М	П6-222М	HL 050	HL 050	HL 050	HL 050
Тип МШУ	нет	Вкл	Выкл	Вкл	1-1М	1-1М	1-1М	1-1М
Полоса пропускания, ГГц	0,85.. 5,0	1,0.. 5,0	1,0.. 5,0	1,0.. 5,0	2,0.. 4,0	2,0.. 4,0	2,0.. 4,0	2,0.. 4,0
Кратность сканирования сигнала	1	1	1	1	1	1	5	-
Кратность сканирования фона	10	10	10	10	10	5	5	1

В каждом эксперименте регистрировалось от 2000 до 5150 значений АЧХ. Для обработки цифрового массива данных и выделения микроволновых всплесков на языке программирования Python (Пайтон) было разработано специализированное программное обеспечение (СПО) предварительного статистического анализа.

Программа **Spikes** выполняет:

1) подсчет существенных микроволновых всплесков (μ-спайков), т.е. почастотный подсчет количества превышений амплитуды (энергии) сигнала над фоном при заданном пороге. Экспериментальным образом порог был выбран в 2,2 дБм.

2) в цифровом виде фиксирует и в графическом виде отображает распределение μ-спайков по частотной шкале в рамках полосы пропускания, что, помимо самостоятельного значения, будет служить данными для более глубокого статистического анализа.

Программа **Sum_spikes** позволяет графически сравнивать в рамках одной серии экспериментов суммарные μ-спайки при разных стимулах (СВЕТ/ТЕМНОТА).

На рис. 1, 2 показан пример обработки программой Spikes сигналов и фона, зарегистрированных АС R&S®ESW.

Рис. 1. АХЧ сигнала с правого затылка головы (более светлая полоса снизу) и фона (более темная полоса сверху). Серия 2. Эксперимент 4. Стимул СВЕТ

Рис. 2. Выделение программой Spikes существенных микроволновых всплесков сигнала над фоном (μ-спайков) из АЧХ эксперимента 4 серии 2 и их распределение по частотной шкале. Стимул СВЕТ

Пример выделения программой Sum_spikes существенных микроволновых всплесков (μ-спайков) для всех 10 экспериментов серии 2 программой Sum_spikes показан на рис. 3.

Рис. 3. Суммарные μ-спайки в 10 экспериментах серии 2.
Нижняя для стимула СВЕТ, верхняя для стимула ТЕМНОТА

Рис. 4. Редкие μ-спайки для контрольного образца (5 экспериментов серия 6).
Пунктирная линия для стимула СВЕТ, сплошная – для стимула ТЕМНОТА

На рис. 4 представлено распределение суммарных μ-спайков для контрольного образца (серия 6, 5 экспериментов). Характер распределения существенно отличается от зарегистрированных с головы волонтера. Здесь

наблюдаются редкие разовые μ-спайки, не превышающие 3 в эксперименте 4, в то время, например, как минимальное число μ-спайков в экспериментах серии 2 равно 30, а максимальное 66.

Программы обработки сигналов позволили провести анализ фона в течение всего времени исследования.

Для 10-кратного накопления фона в серии 2 при свете и в темноте μ-спайки не были обнаружены.

При сравнении между собой фонов всех серий экспериментов при свете и темноте наблюдались только редкие μ-спайки, что естественно в условиях интенсивной индустриальной радиочастотной активности в центре г. Москвы в диапазоне 1,0..5,0 ГГц (GSM, WiFi, WiMAX) при невозможности полной изоляции в БЭК от наружных помеховых сигналов, высокой чувствительности измерительного оборудования и регистрации сигналов на уровне теплового шума.

Выводы

1. В исследуемом диапазоне частот 1..5 ГГц зарегистрировано множество существенных всплесков микроволнового излучения с поверхности скальпа головы человека над фоном как при свете, так и в темноте, что подтверждает методику измерений.
2. Количество существенных всплесков со скальпа головы человека значительно больше, чем от контрольного образца, что подтверждается в большой серии экспериментов. Этим экспериментально подтверждается внутренний источник микроволнового излучения головного мозга.
3. В темноте суммарное количество существенных всплесков на исследуемом диапазоне частот 1..5 ГГц заметно больше чем при свете, что может свидетельствовать о когнитивном характере регистрируемых существенных всплесков. Данный результат не зависит от типа измерительной антенны.
4. Не наблюдается существенного отличия по чувствительности между антеннами R&S HL050 с внешним МШУ и отечественной П6-222М со встроенным МШУ. Это позволяет провести исследования одновременно 2-мя антеннами П6-222М, которые более доступны и могут исследовать место расположения источника микроволнового излучения.
5. Полученные результаты позволяют уточнить техническое задание для разработки многоканального микроволнового радиометра реального времени для исследования пространственного картирования источников микроволнового излучения и разработки технологии микроволновой энцефалографии МВЭГ [9].

Список литературы

1. Брусиловский Л.И., Кожин С.П., Мужичков В.В. Методика экспериментальной регистрации микроволновых излучений головного мозга человека Сборник трудов XVII Всероссийской школы-семинара «Волновые явления в неоднородных средах» имени А.ПР. Сухорукова («Волны-2020») ISBN 978-5-6045125-0-0.

2. Патент RU 2708040 C2, IPC A61B 5/05, G01R 23/00, G01R 33/02. Способ регистрации микроволновой электромагнитной активности головного мозга человека / Авторы, заявители и патентообладатели Брюховецкий А.С., Брусиловский Л.И. - № 2017126117/14; заявл. 20.07.2017; опубл. 03.12.2019, Бюл. № 34.

3. Брусиловский Л.И., Брюховецкий А.С., Разработка технологии микроволновой энцефалографии (MWEG) для диагностики нервных заболеваний и психических расстройств головного мозга человека, изучение активности человека в норме и организация нового типа нейрокомпьютерного интерфейса, Международный симпозиум IEEE «Обработка видео и аудио сигналов в контексте нейротехнологий», SPCN-2017, С-Пб.

4. Andrey S.Bryukhovetskiy, Leonid I. Brusilovsky, Sergey P. Kozhin, Pavel G. Serafimovich, Artem V. Nikonorov, Maria Zhukova and Hari S. Sharma Human mind has microwave electromagnetic nature and can be recorded and processed, Neuropharmacology of Neuroprotection: Volume 258, Series: Progress in Brain Research, pp. 439-462, Elsevier 2020, Hardcover: 978-0-12-820813-7 DOI: 10.18127/j15604128-202003-05.

5. Брусиловский Л.И., Брюховецкий А.С., Кожин С.П., Серафимович П.Г., Никоноров А.В. Экспериментальные исследования микроволновой электромагнитной активности головного мозга человека, Журнал радиоэлектроники [электронный журнал]. 2020. № 2. (журнал ВАК) http://jre.cplire.ru/jre/feb20/2/text.pdf DOI 10.30898/1684-1719.2020.2.2.

6. Румянцев К.В., Анализ спектра и сигналов: современный подход, тенденции и перспективы развития, вебинар Rohde & Schwarz Рус 4.06.2020, https://youtu.be/GfYqGwpbQes.

7. Веснин С.Г. «Антенна-аппликатор для неинвазивного измерения температуры внутренних тканей биологического объекта» Патент РФ 2306 099 C2.

8. Гудков А.Г., Леушин В.Ю., Сидоров И.А., Веснин С.Г. и др. «Использование метода многоканальной микроволновой радиометрии для функциональной диагностики головного мозга», ДВГМУ, Медицинская техника, 2019. № 2 с. 108–111.

9. Л.И. Брусиловский, С.П. Кожин, В.В. Мужичков. Разработка многоканального микроволнового радиометра реального времени для регистрации собственных микроволновых излучений головного мозга человека, Сборник трудов XXXII Всероссийской школы-семинара «Волновые явления: физика и применения» имени А.ПР. Сухорукова («Волны-2021») (ISBN 978-5-6045125-1-7).

Секция

Нейронные сети и когнитивные науки

В.В. КОЗУНОВ
Центр нейрокогнитивных исследований (МЭГ-Центр),
Московский государственный психолого-педагогический университет
kozunov.vladimir@gmail.com

ПРОСТРАНСТВЕННОЕ РАЗРЕШЕНИЕ ДЛЯ АНАЛИЗА СООТВЕТСТВИЯ ПРЕДСТАВЛЕНИЙ В ИССЛЕДОВАНИЯХ С ПОМОЩЬЮ МАГНИТОЭНЦЕФАЛОГРАФИИ

Анализ соответствия представлений обеспечивает широкие возможности для интерпретации данных, полученных с помощью различных техник измерения мозговой активности. Однако его применение для сопоставления лишенных пространственного или временного измерения представлений может сопровождаться потерей информации, которую потенциально несет отдельно взятая техника нейровизуализации. Предложен метод локализации в мозге активности, соответствующей представлениям, полученным исключительно из данных магнитоэнцефалографии.

Ключевые слова: *анализ соответствия представлений, магнитоэнцефалография, локализация активности, зрительное восприятие.*

Введение

Фундаментальная задача когнитивной нейронауки состоит в том, чтобы количественно связать три ее основных направления исследований: измерение мозговой активности, регистрацию поведения и вычислительное моделирование. Эта задача осложняется необходимостью определения соответствия между параметрами моделей и измеренными значениями активности. Аналогичные проблемы возникают при сопоставлении активности между различными модальностями измерения (например, фМРТ и инвазивной или неинвазивной энцефалографией), а также между различными субъектами и, тем более, видами. Для преодоления подобных проблем сопоставления был предложен [1] метод анализа соответствия представлений

(АСП; Representational similarity analysis − RSA). Основная идея подхода заключается в абстрагировании от самих параметров модели и измеренных значений и переходе к анализу сходства-несходства между соответствующими представлениями, которые определяются количественными соотношениями, соответственно, между параметрами модели и паттернами измеренных значений.

Часто при измерении мозговой активности анализ данных основан на предположении, что если одни и те же паттерны активности регистрируются в двух различных условиях (экспериментах), то можно ожидать хотя бы частичное совпадение их порождающих процессов. Однако разные техники измерения порождают принципиально различные паттерны активности. Например, инвазивная электрофизиология измеряет электрическую активность отдельных клеток, тогда как фМРТ измеряет гемодинамический аспект мозговой активности. Карты активаций фМРТ смещены во времени и сглажены в пространстве, поэтому их прямое сопоставление с активностью отдельных нейронов не представляется возможным. Более того, даже в одной модальности измерений часто остро стоит проблема корегистрации активности между различными субъектами. Если не рассматривать частный случай изучения активаций в первичных сенсорных или моторных отделах коры, где, например, ретинотопия или тонотопия обуславливают возможность нахождения повоксельного (повертексного) соответствия между различными субъектами, то совпадение у разных субъектов тонкой структуры активности (в отличие от интегральной активации крупных функционально-анатомических областей) является крайне маловероятным.

Если отражение параметра модели или поведенческой реакции в паттерне активности мозга назвать изоморфизмом первого порядка, то основной концепцией АСП является изоморфизм второго порядка. Когда мы сталкиваемся с трудностями установления прямого соответствия между стимулами и соответствующими им паттернами активности (например, из-за необходимости проведения статистического анализа и, соответственно, корегистрации между субъектами), мы можем вместо этого попытаться установить соответствие между отношениями (представлениями) модельных параметров, с одной стороны, и отношениями (представлениями) измеренных паттернов мозговой активности, т. е. изоморфизм второго порядка. В АСП этот подход реализуется путем сравнения матриц несходства представлений (МНП; representational dissimilarity matrices – RDM). Здесь необходимо сделать замечание о терминологии – слово «представление» в МНП должно пониматься так, что вся МНП является представлением (второй уровень), но в ее отдельных ячейках содержатся оценки несходства паттернов активности (первый уровень). Для теоретической (в частности, вычислительной) модели, которая

может дифференцировать те же экспериментальные условия (стимулы), может быть сходным образом получена (модельная) МНП, так чтобы в ее ячейках содержались оценки различий соответствующих параметров. Нахождение степени изоморфизма второго порядка заключается в количественном сравнении экспериментальной и модельной МНП, например, с использованием корреляционного расстояния.

На основе АСП была предпринята попытка объединения сильных сторон двух различных техник нейровизуализации: пространственного разрешения фМРТ и временного разрешения магнитоэнцефалографии (МЭГ). В недавней работе [2] авторы изучали пространственно-временную динамику в коре головного мозга человека во время зрительного распознавания предметов, сравнивая представления полученные с помощью фМРТ с представлениями МЭГ. Они рассчитывали коэффициент корреляции между МНП МЭГ для каждой временной точки (в пространстве сенсоров) и МНП фМРТ для каждого вокселя. Это позволило связать определенные участки мозга с конкретными моментами времени, давая пространственно-временное представление о зрительной обработке стимулов в мозге. Естественным ограничением данного подхода является то, что в сглаженной во времени активности фМРТ ряд отдельных быстропротекающих этапов зрительной обработки могут не иметь дифференцируемых представлений. Соответственно, часть хорошо дифференцируемых МНП МЭГ не находит своей локализации.

Для решения этой проблемы мы здесь предлагаем другой подход, позволяющий извлекать пространственно-временные карты представлений отдельных этапов обработки в мозге исключительно из измерений МЭГ.

Методы

В предлагаемом подходе мы рассчитываем экспериментальные МНП не в пространстве сенсоров МЭГ, а в пространстве источников. Для перехода в пространство источников мы применяли метод решения обратной задачи МЭГ, в котором потенциальные источники рассматриваются как диполи, лежащие исключительно на коре с фиксированной, нормальной к поверхности коры ориентацией. Поверхность коры представлялась на основе индивидуальных для каждого испытуемого структурных МРТ сканов высокого разрешения. Сегментация структурных сканов производилась с помощью программного обеспечения FreeSurfer [3], и сегмент серого вещества использовался для построения непрерывной триангуляционной сетки, представляющей неокортекс. Задание прямой модели и расчет оператора

обратной задачи (sLORETA) были выполнены с помощью программного обеспечения Brainstorm [4].

В результате вышеописанных процедур для каждого субъекта (испытуемого) получаются проекции измеренной МЭГ активности на фиксированное количество диполей – вертексов триангуляционной решетки (5002 вертекса в нашем эксперименте). Предположение о возможности повертексной корегистрации активностей у разных испытуемых является крайне маловероятным. Поэтому основная концепция нашего подхода состоит в том, чтобы дифференцировать тонкую структуру активности у каждого испытуемого отдельно, выражая степень различий паттернов для крупного функционально-анатомического региона одним числом. Только после перехода к этому скалярному индикатору различий предлагается переходить к оценке сходства между испытуемыми.

Для реализации описанной концепции мы использовали автоматизированную процедуру выделения анатомически гомологичных областей коры головного мозга человека. Взяв за основу атлас Дестрьё с 148 регионами коры, покрывающими почти всю кору (за исключением некоторых структур медиальной стенки), мы объединили ряд мелких областей в более крупные и, наоборот, разделили некоторые протяженные области височной доли на заднюю и переднюю части. Всего мы получили 82 региона, каждый из которых мог состоять из разного количества вертексов для разных испытуемых, но представлял одну и ту же анатомическую структуру с потенциально сходным для разных испытуемых функциональным назначением.

Попарные сравнения паттернов активности для заполнения МНП мы получали с помощью техники многомерной классификации. Для этого мы использовали вариант линейного дискриминантного анализа (ЛДА) из пакета MATLAB. Входные данные для классификатора с временным разрешением были специфичны для каждой из 82 областей. Ключевым фактором для успешной реализации нашего подхода являлось нахождение правильного количества главных компонент, представляющего активность в регионе и определяющего размерность пространства признаков для классификации. Проблема здесь возникала из-за того, что активность в вертексах отдельной области получалась как результат решения обратной задачи, и поэтому не являлась линейно независимой от активности в вертексах других областей. В наиболее неблагоприятном случае вся измеренная сенсорами активность могла быть спроецирована в каждую область, пусть и с не одинаковыми весами. В таком случае классификация с помощью ЛДА по активности одной области будет практически не отличаться от классификации по всем сенсорам. Иначе говоря, это приведет к потере пространственного разрешения. Поэтому выбор правильного количества главных

компонент выражал задачу нахождения оптимального баланса между использованием необходимой для дифференцирования экспериментальных условий размерности пространства признаков и достаточным пространственным разрешением. Мы нашли, что представление активности области тремя главными компонентами удовлетворяет этому условию.

Мы тестировали предлагаемый подход на данных, полученных в эксперименте по исследованию этапов зрительного восприятия [5], в ходе которого испытуемым демонстрировались битональные (черно-белые) изображения из трех групп: лица, инструменты и бессмысленные изображения. Все изображения имели размер 500×500 пикселей и были выровнены по яркости и длине контуров. Показ изображений был разбит на две сессии, в ходе которых изображения демонстрировались в псевдослучайном порядке 80 раз каждое. Данные, соответствующие показу идентичных изображений в двух сессиях, входили в анализ как отдельные условия. После каждого предъявления стимула участники должны были вслух назвать то, что они видели на картинке. Нейромагнитная активность регистрировалась с помощью 306-канальной системы МЭГ «Vectorview» (Neuromag Elekta Oy, Хельсинки, Финляндия).

После стандартных процедур предварительной обработки МЭГ данных мы с помощью ЛДА проводили оценку точности декодирования паттернов вызванной активности для всех возможных пар стимулов для каждой области и каждой временной точки. Генерализация классификатора оценивалась с помощью перекрестной валидации. Для каждого попарного сравнения использовалось 18 проб для обучения (по девять от каждого класса стимулов) и две для проверки классификатора (по одной от каждого класса). Эту процедуру повторяли 100 раз, каждый раз с новой рандомизацией. Эффективность классификатора количественно оценивалась как доля правильно классифицированных проб.

После расчета меры несходства для всех возможных пар паттернов мы перешли к непосредственному применению АСП. Для этого мы сформировали три типа простых модельных МНП, в которых значение 0 символизировало отсутствие дифференциации паттернов, а значение 1 – высокую степень дифференциации. Первый тип МНП − «распознаватель стимулов» (рис. 1) – требовал, чтобы все различия в парах были высокими, за исключением пар идентичных стимулов, представленных в первой и второй сессиях. Второй тип МНП - «осмысленная категория против бессмысленного изображения» − применялся отдельно для категорий лиц и инструментов (ячейки соответствующие сравнениям с другой осмысленной категорией игнорировались). Эти МНП требовали большей несхожести между стиму-

лами из различных групп, чем в пределах одной группы. Третий тип моделей использовался в двух случаях – для выделения активности: 1) различающейся при обработке осмысленных и бессмысленных стимулов независимо от принадлежности первых к конкретной категории, 2) специфической для обработки одной осмысленной категории (при этом дополнительно требовалось, чтобы обработка второй осмысленной категории не отличалась от обработки бессмысленных стимулов). Степень сходства между эмпирическими МНП и модельными МНП оценивались путем вычисления коэффициентов корреляции Спирмена.

Рис. 1. Три типа модельных МНП для анализа экспериментальных данных. Ячейки черного цвета соответствуют высокому значению различий в паре паттернов, ячейки светло-серого цвета - низкому значению различий. Белые ячейки для второго типа МНП игнорировались. Для второго типа показана МНП «лица против бессмысленных). Для третьего типа - «специфичная для лиц обработка» (обработка инструментов не отличается от обработки бессмысленных)

Результаты

Прежде всего мы проверили, была ли точность декодирования выше случайной для паттернов активности источников, ограниченных отдельными областями коры. В табл. 1 представлены характеристики декодируемости, усредненные по всем испытуемым для пяти областей (усредненные по полушариям), простирающихся от затылочных до префронтальных отделов. Мы обнаружили, что точность декодирования была выше случайной, начиная с 50–80 мс после начала стимула для большинства областей мозга, охватывающих всю кору, и для всех пар категорий.

Затем мы исследовали, зависят ли характеристики декодируемости от конкретной области мозга. Момент начала декодирования мы определяли как точку на временной прямой, в который точность декодирования оказы-

валась значимо выше случайной. Средние значения точности рассчитывались для временного окна 50–700 мс. Различия между регионами во времени начала, латентности пика, а также максимальной и средней точности были проверены с использованием бутстраппинга (bootstrapping). Мы обнаружили, что время начала декодирования для окципитального полюса было достоверно раньше, чем для всех других регионов, и для вентральной премоторной области было позже, чем для нижней окципитальной и веретенообразной извилин. Латентность пика повторяла этот паттерн и была достоверно раньше для окципитального полюса чем для всех других регионов, в то время как латентность для вентральной премоторной области была позже, чем для всех других регионов. Все попарные различия максимальной и средней точности для тестируемых регионов были статистически значимыми.

Таблица 1

Средние значения характеристик декодируемости для пяти областей

Регион	Контраст	Начало, мс	Пик, мс	Пик, точность	Средняя точность (std)
Окципитальный полюс	лица-нет	50	340	0.82	0.76(0.053)
	инструменты-нет	50	90	0.83	0.75(0.049)
	лица-инструменты	50	90	0.85	0.76(0.055)
	среднее	***50***	***90***	***0.83***	***0.76(0.051)***
Нижняя окципитальная извилина	лица-нет	60	150	0.82	0.72(0.061)
	инструменты-нет	60	320	0.76	0.70(0.052)
	лица-инструменты	60	150	0.80	0.71(0.053)
	среднее	***60***	***150***	***0.77***	***0.71(0.053)***
Веретенообразная извилина	лица-нет	60	150	0.75	0.67(0.044)
	инструменты-нет	60	340	0.70	0.65(0.041)
	лица-инструменты	60	150	0.73	0.66(0.039)
	среднее	***60***	***150***	***0.70***	***0.66(0.038)***
Внутритеменная борозда	лица-нет	70	310	0.66	0.63(0.034)
	инструменты-нет	70	340	0.67	0.63(0.034)
	лица-инструменты	60	330	0.66	0.63(0.031)
	среднее	***70***	***320***	***0.66***	***0.63(0.032)***
Вентральная премоторная область	лица-нет	100	480	0.63	0.60(0.026)
	инструменты-нет	110	560	0.64	0.60(0.038)
	лица-инструменты	70	360	0.63	0.59(0.024)
	среднее	***80***	***460***	***0.62***	***0.60(0.028)***

Далее мы перешли непосредственно к применению АСП. Прежде всего мы проверили, обеспечивает ли наш подход различную локализацию выделяемой разными модельными МНП активности. Мы взяли для каждой области мозга преобразованные по Фишеру коэффициенты корреляции Спирмена между экспериментальными МНП и тремя модельными МНП: «распознаватель стимулов»; «лица против бессмысленных»; и «инструменты против бессмысленных», и усреднили их по временному окну 50–400 мс, а также по гомологичным областям обоих полушарий, получив в общей

сложности значения для сорок одной области. Затем мы провели многомерный дисперсионный анализ (MANOVA), чтобы проверить, существенно ли различаются векторы корреляций, соответствующих 41 области, для разных моделей. Анализ показал, что средние значения не лежали на одной прямой ($\chi2(40) = 66{,}63$, $p < 0{,}006$), т.е. отдельные функциональные компоненты, извлеченные с помощью различных модельных МНП, имеют уникальное пространственное распределение.

Вышеприведенный результат основан на средних значениях за длительные интервалы времени. Полный потенциал применения нашего подхода к анализу МЭГ данных, однако, раскрывается в ходе анализа с временным разрешением. Такой анализ позволил нам выделить три этапа обработки зрительных стимулов, соответствующих низкоуровневому анализу зрительных признаков, категория-специфичному связыванию признаков и появлению осмысленности воспринимаемого предмета (рис. 2).

Первый этап был выделен с помощью МНП «распознаватель стимулов». Данная модель позволяет находить активность уникальную для каждого стимула и может интерпретироваться как низкоуровневый анализ зрительных признаков. Этот этап начинается в 50 мс и заканчивается в 110 мс после подачи стимула, что соответствует временному окну компонента P100. Начало первого этапа соответствует самому раннему моменту, когда данные МЭГ позволяют декодировать паттерны стимулов в пространстве сенсоров [6]. Здесь мы воспроизвели этот результат, но в пространстве источников на основе данных, ограниченных определенными областями коры. Это позволило определить локализацию активности, связанной с выделением низкоуровневых зрительных признаков, в первичных и вторичных областях зрительной коры.

Обработка на первом этапе не устанавливает связь между пространственными характеристиками зрительного входа и семантическим значением, определяющим принадлежность предмета к категории. Для нахождения пространственно-временных параметров процесса, с помощью которого пространственные статистики преобразуются в пространственно инвариантные представления, мы отдельно для каждой категории применяли МНП второго типа. Мы обнаружили, что второй этап обработки, отвечающий за категория-специфичную интеграцию зрительных признаков, длился от 120 до 240 мс после начала стимула и вовлекал постериорные области затылочно-височной и частично теменной коры без заметного вовлечения первичных отделов зрительной коры (рис. 2 – второй ряд).

Третий этап был выделен с помощью МНП третьего типа, которая контрастировала различия между обработкой осмысленных и бессмысленных изображений независимо от их принадлежности к конкретной категории.

Иными словами, на этом этапе преобладают отличия, характеризующие сам факт появления осмысленности воспринимаемого предмета (при этом мы не утверждаем, что полностью отсутствует категория-специфичная активность). Мы нашли, что во временном окне 250–500 мс широкая сеть передних височных, теменных и лобных областей демонстрировала активность (рис. 2 − нижний ряд), которая с очень высокой точностью дифференцировала обработку осмысленных изображений от бессмысленных. Такая устойчивая, но не избирательная для конкретной категории активация в широко распределенных областях теменной, височной и префронтальной коры может быть связана с подготовкой активной реакции, явной или скрытой, которой заканчивается акт осмысленного восприятия.

Рис. 2. Пространственные карты активности, соответствующей трем этапам обработки зрительных стимулов. Светло-серым цветом обозначены активные области. На втором этапе представлено объединение категория-специфичных областей для лиц и инструментов

Заключение

Считается, что современные методы нейровизуализации по отдельности не могут отображать пространственно-временные характеристики активности мозга, потому что они обеспечивают либо высокое простран-

ственное, либо высокое временное разрешение, но не то и другое одновременно. Это является серьезным препятствием на пути экспериментальной проверки теоретических и вычислительных моделей, поскольку встает проблема нахождения соответствия между динамическими параметрами модели и потерявшими либо пространственное, либо временное измерение значениями активности.

Здесь мы предложили метод, позволяющий извлекать достаточно точные пространственно-временные характеристики, соответствующие разнообразным модельным взаимоотношениям между параметрами, исключительно из сигналов МЭГ. Предложенный подход лишен проблемы выделения быстропротекающих процессов, характерной для попыток локализации функциональных компонентов на основе сопоставления с представлениями в сглаженной во времени активности фМРТ. Кроме того, наш метод решает проблему корегистрации анализируемых функциональных зависимостей между субъектами при анализе МЭГ данных, поскольку позволяет отказаться от неправдоподобного требования повертексного совпадения активностей у разных испытуемых. Мы корегистрируем экспериментальные эффекты лишь на уровне крупных областей, для которых совпадение функционального и анатомического сходства между испытуемыми является более физиологически правдоподобным предположением. При этом мы сохраняем способность детекции изменений во внутренней структуре активности областей с точностью до каждого вертекса (или числа главных компонентов, представляющих активность в области).

Список литературы

1. Kriegeskorte N., Mur M., Bandettini P. A. Representational similarity analysis-connecting the branches of systems neuroscience // Frontiers in systems neuroscience. – 2008. – С. 4.

2. Cichy R. M., Pantazis D., Oliva A. Resolving human object recognition in space and time // Nature neuroscience. – 2014. – Т. 17. – №. 3. – С. 455–462.

3. Dale A. M., Fischl B., Sereno M. I. Cortical surface-based analysis: I. Segmentation and surface reconstruction // Neuroimage. – 1999. – Т. 9. – №. 2. – С. 179–194.

4. Tadel F. et al. Brainstorm: a user-friendly application for MEG/EEG analysis // Computational intelligence and neuroscience. – 2011. – Т. 2011. – С. 1–13.

5. Kozunov V. V. et al. Object recognition is enabled by an experience-dependent appraisal of visual features in the brain's value system // NeuroImage. – 2020. – Т. 221. – С. 117143.

6. Wardle S. G. et al. Perceptual similarity of visual patterns predicts dynamic neural activation patterns measured with MEG // Neuroimage. – 2016. – Т. 132. – С. 59–70.

A. BRUEVA,
J. EDELEVA
Lobachevsky State University (National Research University), Nizhny Novgorod,
University Lane 7, 603022, Russian Federation
kudao1@yuandex.ru

NEGOTIATING COGNITIVE LOAD THROUGH COGNITIVE SKILLS, FOREIGN LANGUAGE PROFICIENCY AND THE STATE OF ANXIETY IN FOREIGN LANGUAGE ORAL PERFORMANCE

Many foreign language learners experience a state of anxiety when taking foreign language exams or communicating in a second language. The state of anxiety might be conditioned by an increased cognitive load during L2 comprehension and production. At the same time, cognitive load is closely related to cognitive skills and, therefore, can be mediated both by external factors such as task complexity and internal factors such as working memory capacity. In the current study, we investigate whether the state of anxiety during L2 oral performance can be relieved as a function of working memory capacity. We elicited spontaneous L2 and L1 oral production data of 16 Russian-speaking participants. Adapted methodology for linguistic analysis in altered states of consciousness was employed to annotate linguistic features of speech produced in a state of anxiety and in a neutral state. Selected disfluency types were identified that are associated with either working memory capacity or with the state of anxiety. Our results reveal that the interrelation between situational and personal anxiety, working memory capacity and the level of L2 proficiency is not statistically significant. Yet, general numeric trends could be observed. The findings have significant implications for the development of automated models of cognitive load estimation. The taxonomy of linguistic features can be used in language teaching and trainings on anxiety reduction through cognitive skill development. Further, the data might be useful to improve machine learning algorithms of affective state estimation based on oral speech data.

Keywords: *cognitive load, anxiety, L2 learners.*

1. Introduction

The term cognitive load originated and further elaborated in the disciplinary field of instructional psychology, pedagogy and the theory of learning. Tradition-

ally, the concept of cognitive load is considered in relation to the concept of mental workload in the field of ergonomics and human factors [1]. In the current study, we define cognitive load as a multidimensional construct triggered by a purely educational task, which distinguishes cognitive load from mental workload in the context of this study. Traditionally, three types of cognitive load are distinguished - intrinsic, extrinsic, and germane [2]. In the current study, we induce extrinsic cognitive load by targeting oral narrative skills in native or foreign languages. We also perform an assessment of anxiety-mediated intrinsic cognitive load.

Cognitive load and the state of anxiety are closely interrelated. The cognitive load theory dates back to early research by Sweller [3] who proposed various types of factors that might influence an individual's relative information processing capacity. Along these lines, cognitive load is mediated by the working memory span which ranges between 5 and 9 items at a given point in time [4]. However, this bottleneck may become narrower under the influence of both extraneous and intrinsic factors inducing an increased cognitive load. Studies have repeatedly reported memory decay under the influence of stress. For instance, Loftus E. and Ketcham K. [5] note that some stimulation methods improve perception and memory, but severe stress makes these processes difficult. Fear negatively affects memory, especially if it reaches the level of hysteria. Since then, a number of complex methods for studying cognitive load have been developed while all the more precise methods including sophisticated computer algorithms continue to emerge [6, 7]. In existing experimental studies, cognitive load is commonly induced via linguistic means such as element connectivity or semantic proximity. Semantically distal items might also constrain depth of their processing [8]. Consequently, the stability of mental representations that are created from the input to be later transferred into long-term memory might be infringed. Fluent non-native speakers whose linguistic performance is barely distinguishable from that of a native speaker still showed a considerable cognitive load penalty in selected psycholinguistic experimental studies [9]. Those studies involved the processing of complex sentences in a self-paced-reading or -listening paradigm. Cognitive load has also been shown to significantly affect the verbal behavior of highly proficient simultaneous translators [10; 11] who are put under a severe pressure by the need to negotiate two languages in two different modalities simultaneously [12].

By contrast, investigations of cognitive load and affective states of language learners in the L2 context are comparatively rare and not uncontroversial. In the experimental study by Curcic [13], the participants had to learn grammatical regularities of an artificial language and were later tested for their ability to make a language prediction. The cognitive resource underpinning language prediction in

a less familiar language was measured with the help of implicit metrics such as eye tracking. The study did not reveal any significant interrelation between the level of cognitive load and the participants' knowledge of grammatical regularities in the artificial language. In a further experimental study by Nawal [14], the participants had to assess their perceived level of cognitive load subjectively while they were requested to generate written productions in a foreign language. Experimental participants reported an increase in the cognitive load after writing an essay in a foreign language. The study by Roussel et al. [15] examined how the level of cognitive load experienced by the participants depends on their foreign language skills. They used auditory linguistic material in L1 French and L2 English. One participant group first heard the university lecture in their L1 and then in their L2. In the other participant group, the order of the presentation was reversed. The results of the study show that the level of cognitive load gradually decreases when the information is first presented in the native language and then in the L2.

As can be concluded, the studies into native speakers and language learners that have been briefly reviewed point at the interrelation between cognitive load, the state of anxiety and L2 performance. At the same time, the state of anxiety might be indirectly conditioned by an increased cognitive load during L2 comprehension and production which has been considered in a number of research papers [16, 17, 18, 19]. However, none of the studies systematically investigates how verbal performance of language learners is affected by the level of cognitive load which might in turn be modulated by anxiety that they experience when they have to express themselves in an L2 (though cf. the study by Chow et al. [7] which examines how L2 reading performance is modulated by working memory capacity and reading anxiety). The current study aims to close this gap and examines whether there is an inverse relation between cognitive skills and the state of anxiety, i.e., whether more advanced cognitive skills (L2 proficiency and the working memory span) may mitigate L2 speaking anxiety.

Our findings have significant implications for the development of automated methods of cognitive load assessment. Since cognitive load is assumed to be modulated by anxiety, optimized machine learning methods should take into account both L2 learners' cognitive skills and their psychophysiological states. Individual assessment of the learners' capabilities will provide tailor-made learning scenarios in the context of technology-mediated learning [20].

2. Methods

16 Russian-speaking subjects (8 females) aged 19 to 24 years were recruited for the study. Their participation was voluntary. Prior to the experiment, they

were requested to provide their informed consent for their oral performance to be audio-recorded during the study. The C-test [21] was used to assess their level of proficiency in L2 English as a reliable measure of global language proficiency [22] Though there is no conventional approach to assess psychological states during L2 speech activity, subjective anxiety metrics were used in similar studies. Chow et al. [23] examined the students' anxiety via the State-Trait Anxiety Inventory and related their perceived state to their L2 reading performance. Since the results they obtained have a high interpretive power and can serve as a reference point for the current study, we adopted the procedure implemented there. To assess the working memory capacity of the participants, a classical digit memory span task was implemented due to is intuitive nature and time efficiency. Finally, the State-Trait Anxiety Inventory was administered to estimate the current state of the psyche at a particular point in time.

We manipulated the level of cognitive load in that we asked the participants to first deliver a narrative in their L2 and then in their L1. In this case, their verbal performance in the L2 should be more taxing in terms of cognitive level (cf. [15]).

The experiment consisted in the following steps.

I. **Working Memory Span test** is carried out using the online platform mybraintest.org; the Free Short Term Span Memory Test [24] was proposed for measurement. The test allows to identify the range of simultaneously memorized digits.

II. **L2 proficiency** is assessed using the C-test [25; 26]. The format of the test involves filling in gaps (endings of word forms) in a short text on a general topic. The test has a subordinate function to activate L2 for the subsequent narrative task.

III. **Image-triggered narrative in L2.** The image source was MAIN [27], a multilingual narrative assessment tool developed as part of the LITMUS test suite. The stories contained in the images are controlled for cognitive and linguistic complexity, macro- and microstructure parallelism and are primarily designed for children.

IV. **The level of anxiety** was assessed twice immediately after the L2 speaking task and after the L1 speaking task. Baseline anxiety assessment prior to the L2 speaking task was not carried out because in this case a particular anxiety level might be provoked by the upcoming language assessment. Anxiety is assessed using the Spielberg test. The test consists of 40 questions. The first half of the questions is focused on identifying the level of situational anxiety that is expected to be caused by L2 speaking. A further set of 20 questions is focused on identifying the level of personal anxiety [28; 29].

V. **A demographics questionnaire** involves a set of direct questions about the subjects' demographic data: gender, age, study major, mother tongue, second language. Additionally, this stage of the experiment allows respondents to reduce the cognitive load when switching to L1.

VI. **Image-triggered narrative in L1** involves composing a story from an already familiar picture from the MAIN database [27; 30], so the level of anxiety can be reduced by not only speaking in L1, but describing the story from an already familiar image.

VII. **Reassessment of the level of anxiety** is carried out immediately after the end of speaking in their native language. Testing is also carried out using the Spielberg test which allows us to compare the level of situational anxiety after L1 and L2 speaking task.

3. Results

As one of the participants failed to comply with the experimental procedures, their data were excluded from further evaluation. The audio-recordings from the remaining 16 participants were manually transcribed and annotated for disfluencies as to the guidelines that we derived from Sineokova [31] and adapted for the purposes of the current study [32]. Oral productions in L1 and in L2 were annotated for the following linguistic parameters: repetitions, redundancies per number of sentences and utterances; transpositions, elaborations per number of sentences; exclamatory constructions; statements per number of sentences and utterances; average sentence length (in words); average utterance length (in words and sentences).

Annotation data per participant (1-16) and language (R – L1 Russian, E – L2 English) are summarized in Fig. 1. The stacks of the bar chart are color-coded for the average number of occurrences for each respective linguistic feature. The values were normalized respective to the number of words. Accordingly, the higher the bar itself, the less common a particular speech marker is in a participant's oral production. Overall, the utterances were shorter in L2 English compared to L2 Russian. Consequently, the linguistic markers occurred more frequently in foreign compared to native oral productions since the occurrence ratio per number of words is higher. In a more detailed by-participant analysis, four participants (No. 3, No. 5, No. 11, No. 15) were detected whose L2 productions evidenced fewer speech markers than their corresponding L1 productions. Though they constitute around a third of the entire sample, it still does not revert the overall trend towards higher occurrence of speech markers in L2 compared to L1.

Fig. 1. Descriptive statistics for the distribution of disfluency markers per participant and text sample (L1 Russian, L2 English)

In the next step, correlations were computed for individual speech markers and the participants' scores on the situational anxiety inventory, their working memory capacity and their level of L2 proficiency. Social anxiety scores were directly correlated with the number of pauses and repetitions while sentence length showed an inverse correlation (cf. Table 1). Working memory capacity was positively associated with sentence length in words and negatively interrelated with redundancies and transpositions. The latter also showed an inverse correlation with L2 proficiency. Generally, the average number of speech markers decreases, the more developed language skills are.

By contrast, correlations between situational anxiety, working memory capacity, L2 proficiency and the level of personal anxiety are weak. The interdependence of these values is not statistically significant (cf. Table 2).

In summary, disfluency markers were more common in L2 than in L1 oral productions. Further, we observed a correlation of the participants' cognitive (L2 proficiency, working memory span) and affective (the state of anxiety) variables with selected disfluency markers. Generally, occurrence of disfluencies was reduced in participants with more developed cognitive skills. Yet, the correlations between cognitive skills and affective states showed only a numeric trend, but were not statistically significant.

Table 1

Correlation of linguistic markers with the degree of situational anxiety

Linguistic parameters	Correlation coefficient to the degree of situational anxiety	Interpretation of bond strength on the Chaddock scale	Student's t-test	Interpretation of the critical value of Student's t-test
Repetitions	0.540	Noticeable	3.510	**p=0.001485**
Pauses	0.474	Moderate, tending to noticeable	2.948	**p=0.006257**
Redundancies	0.101	Weak	0.559	p=0.580737
Transpositions	0.268	Weak, tending to moderate	1.523	p=0.138520
Elaborations per number of sentences	0.234	Weak	1.316	p=0.198393
Average sentence length (in words)	-0.582	Noticeable	3.919	**p=0.000498**
Average utterance length (in words)	0.050	Weak, tending to null	0.273	p=0.786527
Average utterance length (in sentences)	0.459	Moderate, tending to noticeable	2.829	**p=0.008380**

Table 2

Correlation of cognitive indicators and the level of personal anxiety with the level of situational anxiety

Parameters	Correlation coefficient to the degree of situational anxiety	Interpretation of bond strength on the Chaddock scale	Student's t-test	Interpretation of the critical value of Student's t-test
Personal anxiety	0.199	Weak	1.113	p=0.274680
Working memory capacity	-0.171	Weak	0.949	p=0.350456
L2 proficiency	-0.232	Weak	1.303	p=0.202691

4. Discussion

In the current study, we investigated how the degree of anxiety during L2 oral production is modulated by working memory capacity and L2 proficiency. Further, we inquired whether there are specific disfluency markers that can be associated with the cognitive skills and affective states. We employed an adapted version of the taxonomy of disfluencies originally developed by Sineokova [31] to identify emotional stress. Though the original version of the taxonomy does not fully explicate the state of anxiety or the degree of is situational manifestation, we could identify some linguistic features that are indeed strongly correlated with situational anxiety scores. They include repetitions, redundancies and transpositions. Two additional parameters – pauses and sentence length in words – were detected in the current study. Thus, an increase in the degree of anxiety manifestation brings about a greater number of disfluencies and distorts natural speech flow during language production. Developing a fully comprehensive method that would allow to distinguish anxiety from other altered states of consciousness. To determine the level of situational anxiety for L1 and L2 oral productions, we used a questionnaire which tapped into the participants' subjective assessment of their state of consciousness. Though the use of implicit metrics such as heart rate might have delivered more accurate results, we were primarily interested in the perceived manifestation of anxiety that the participants become consciously aware of. At the same time, our results align with those that used more objective metrics [33; 11]. In line with the findings in Bakhuchina et al. [33], we found that subjective situational anxiety is expressed in the number of pauses as well. Subjective assessment is also considered more informative by other researchers in the field [14].

Though our results are to be treated with caution considering a sparse sample size, the numeric trends are in line with our research expectations. Specifically, a high level of situational anxiety can be associated with a high level of personal anxiety and reduced working memory capacity as well as a lower level of foreign language proficiency (English). Supposedly, a lager data sample is needed for the indicated trend to reach statistical significance. The visual images that we used to elicit oral productions in L1 and in L2 were culture-neutral, but at the same time originally designed for pre- and early-school children. More adult-like stimulus materials or other text genres, such as argumentations, should be explored in further studies to eliminate this bias. Finally, though the C-test is a proven measure of global language proficiency [24] and has a high discriminative power regarding language learners' L2 performance, it might have been beneficial to use a proficiency metric that explicitly targets language learners' speaking skills.

However, if we split our entire sample into those participants with above- and below-average working memory capacity, we can notice obvious qualitative differences in their L2 oral performance. The participants with a higher working memory span generally produced more propositionally-filled utterances contributing to the gradual development of the narrative. By contrast, the subjects with reduced memory capacity delivered less contentual information and skipping some of the image frames that were critical for the narrative development. In addition, there is an empirical tendency for the subjects with reduced working memory capacity to use simple sentences with an abundance of repetitions that practically do not introduce new information within a single phrase. At the same time high working memory participants tend to use complex sentences where longer sentences are equivalent to a whole phrase. Therefore, the inverse correlation between the level of working memory and the length of phrases in words and sentences is not represented in our study. In summary, stable cognitive skills generally condition a more normalized flow of speech.

Evaluating our own results, we cannot but relate them to some prominent studies in the field. A recent investigation by Roussel et al. [15] emphasizes the shortcomings of modern curricula that do not take into account the extremely high cognitive load induced by L2 listening for comprehension. A further study [23] points at the reciprocity between the level of cognitive skills and the participants' affective state. Cognitive load in an L2 context can be reduced through the development of cognitive skills, in particular, verbal working memory. Further, the authors point out that reading anxiety reduces verbal working memory and interferes with reading comprehension, so it is important to work not only developing cognitive skills, but also on reducing general L2 anxiety.

In the current study, we observed that both the situational anxiety and reduced working memory capacity impair the natural speech flow, both in the L1 and in the L2. However, the interrelation between these parameters showed only a numeric trend. A number of scientific papers evidence that the dynamics of brain activity are modulated by the level of cognitive load [34; 35]. For this reason, our results have direct implications for the field of neuroinformatics. First, we could identify different disfluencies that are negatively and positively associated either with the working memory capacity or the state of anxiety. Those statistical differences will allow to train more advanced mathematical algorithms to detect cognitive and affective states separately. Additionally, the data may become relevant for computational models of germane cognitive load where both cognitive skills and affective states should be taken into account. A more differentiated automated assessment of the learners' psychophysiological state based on their oral speech data will con-

tribute to the development and selection of teaching and learning materials. Further, such automated mathematical algorithms will compensate for possible anxiety levels that naturally emerge during L2 speaking assessment.

5. Conclusion

Drawing on existing studies of the interrelation between cognitive and affective states in the L2 context, the current study encourages further larger-scale research into the role of cognitive load in language learning. The study of the relationship between cognitive functions and the level of anxiety may well serve as a basis for developing more ergonomic teaching and learning materials and didactic tools. More comfortable language learning conditions can be created for groups of students with reduced cognitive functions and, as a result, a high degree of individual anxiety in the classroom.

A comprehensive study of cognitive load and anxiety may also improve specific machine learning procedures to adjust the selection and adaptation of tasks and other learning materials for students commensurate with the level of cognitive load and anxiety. Though the approach proposed in the current study still needs to be refined, it demonstrates a large inclusive potential for applied purposes. Since it operates on oral speech data, it allows to address learner groups with marginal or decaying literacy skills.

References

1. G. Orru, L. Longo, The evolution of cognitive load theory and the measurement of its intrinsic, extraneous and germane loads: a review. In Human Mental Workload: Models and Applications: Second International Symposium, H-WORKLOAD 2018, Amsterdam, The Netherlands, September 20-21, 2018, Revised Selected Papers 2 (p. 23-48. Springer International Publishing) (2019).
2. J. Sweller, J. J. Van Merrienboer, F.G. Paas, Cognitive architecture and instructional design. Educational psychology review, 10(3), 251–296 (1998).
3. J. Sweller. Cognitive load during problem solving: Effects on learning, Cognitive Science 12 (2)). P. 257–285 (1988).
4. G. A. Miller, The magic number seven, plus or minus two: some limitations on our capability for processing information, The Psychology Review. (1956) Vol. 63. Vol. 2. (1956).
5. E. Loftus, K. Ketcham, Defense Witness: Shocking Evidence for the Vulnerability of Our Memories: Hummingbird, ABC-Atticus; p. 412 (2018).
6. B. B. Velichkovsky, New oculomotor assessment methods cognitive load, Questions of psychology N.1. P. 119-129. (2021).
7. S. M. Goryushko, A.V. Samochadin, Means for assessing the level of cognitive load in the learning process, Computer tools in education. N. 4. P. 35-44 (2018).

8. F.I. Craik, R. S. Lockhart, Levels of processing. A framework for memory research. Journal of Verbal Learning and Verbal Behavior. V. 11. N.6. P. 671–684. (1972).

9. A. Ketzer-N√rltge, Sentence processing in the first and second language German: memory performance and cognitive load. Peter Lang GmbH, International Publisher of Science (2019).

10. M.V. Tomskaya, Speech behavior of a simultaneous interpreter when cognitive load. Science without borders: synergy of theories, methods and practitioner. P. 306–308 (2020).

11. D. V. Balaganov, Influence of stress on the activity of a simultaneous interpreter. Philological Sciences. Questions of theory and practice. Tambov: Diploma, No. 12 (90). Part 1. P. 74–79 (2018).

12. I. S. Parina, S. B. Parin, Study of the level of stress in novice simultaneous interpreters in the framework of the cognitive paradigm, Questions of Psycholinguistics. no. 2 (40). P. 124–134 (2019).

13. M. Curcic, S. Andringa, F. Kuiken, The role of awareness and cognitive aptitudes in L2 predictive language processing, Language Learning. Vol. 69. P. 42–71 (2019).

14. A. F. Nawal Cognitive load theory in the context of second language academic writing, Higher Education Pedagogies. Vol. 3. №. 1. P. 385–402 (2018).

15. S. Roussel, A. Tricot, J. Sweller, The advantages of listening to academic content in a second language may be outweighed by disadvantages: A cognitive load theory approach, British Journal of Educational Psychology. Vol. 92. №. 2. P. e12468. (2022).

16. A.Y. Kalinin, Cognitive and pragmatic aspects of simultaneous translation into a foreign language, Bulletin of the Moscow State Linguistic University. Humanitarian sciences. no. 2 (844). P. 204–217 (2021).

17. E. Gibson, E. Fedorenko, The need for quantitative methods in syntax and semantics research, Language and Cognitive Processes. Vol. 28. №. 1-2. P. 88–124 (2013).

18. E. Gibson, Linguistic complexity: Locality of syntactic dependencies, Cognition. Vol. 68. №. 1. P. 1–76 (1998).

19. M. V. Tomskaya, Polymodal aspect of studying the speech behavior of a simultaneous interpreter under cognitive load, Bulletin of the Moscow State Linguistic University. Humanitarian sciences. no. 3 (819). P. 218–226 (2019).

20. E. E. Kotova, I. A. Pisarev, Automated system for analyzing cognitive load in the Blended Learning environment, LBC: 3973.233. 02y43+ 3973.233-018.2y43 P79. Vol. 15. P.145 (2022).

21. URL: https://wuster.uab.es/ctestpracticer/ct?x=kaieteur

22. V. A. Demareva, J. A. Edeleva, & I.Petrova (submitted). Global Eye Movement Measures as Correlates of L2 Proficiency. Journal of Language and Education.

23. B. W. Y Chow., J. Mo, Y. Dong, Roles of reading anxiety and working memory in reading comprehension in English as a second language, Learning and Individual Differences. Vol. 92. P. 102092. (2021).

24. URL: https://www.mybraintest.org/online-memory-screening-tests/

25. URL: https://wuster.uab.es/ctestpracticer/ct?x=kaieteur

26. Z. Dournyei, L. Katona, Validation of the C-test amongst Hungarian EFL learners. Language Testing, 9(2), 187–206 (1992).

27. Multilingual Assessment Instrument for Narratives - Revised material: "Gagarina, N., Klop, D., Kunnari, S., Tantele, K., Vaelimaa, T., Bohnacker, U. Walters, J. (2019). MAIN: Multilingual Assessment Instrument for Narratives - Revised. ZAS Papers in Linguistics 63.

28. C. D. Spielberger, R.L. Gorsuch, R. Lushene, P. R. Vagg, G. A. Jacobs. Manual for the State-Trait Anxiety Inventory. Palo Alto, CA: Consulting Psychologists Press. (1983).

29. URL: https://psytests.org/psystate/spielbergerF8.html

30. URL: https://main.leibniz-zas.de/

31. T.N. Sineokova, Linguistics of altered states of consciousness: a textbook. Nizhny Novgorod State Linguistic University. N.A. Dobrolyubova. P. 151 (2008).

32. A.A. Kudryavtseva, Explication of altered states of consciousness in oral speech, Kurs Study, (2019; 2021; 2022).

33. A. V. Bakhchina., V. A. Demareva, T. N. Sineokova Peculiarities of vegetative reactions of students in prepared monologue and unprepared dialogic speech in a foreign language (problem setting), Theoretical and applied aspects of the study of speech activity. Vol. 10. - No. 3. P. 143–156 (2015).

34. I.S. Polikanova, A.V. Sergeev, A. V. Influence of long-term cognitive load on EEG parameters. National Psychological Journal, (1(13)), 84–9 (2014).

35. V. Yu. Kulikov, L.K. Antropova, E.A. Archibasova, Gender specifics of alpha-rhythm spectral power and heart rate variability under cognitive load in healthy students. Siberian Medical Bulletin, (3), 55–67 (2020).

В.В. КЛИНЬШОВ, А.В. КОВАЛЬЧУК

Институт прикладной физики им. А.В. Гапонова-Грехова
Российской академии наук
vladimir.klinshov@gmail.com

ЧАСТОТНЫЙ ХАОС И ДЛИТЕЛЬНОСТЬ ПАМЯТИ В СПАЙКОВЫХ НЕЙРОННЫХ СЕТЯХ*

Частотный хаос – это коллективное состояние нейронной сети, характеризующееся медленными нерегулярными колебаниями частоты возбуждения отдельных нейронов. Мы изучаем редко связанную сеть спайковых нейронов, которая демонстрирует три различных сценария возникновения частотного хаоса. Хотя все сценарии приводят к коллективной динамике с похожими статистическими характеристиками, оказывается, что последствия для вычислительных возможностей сети при выполнении простой задачи задержки сильно зависят от конкретного сценария.

Ключевые слова: *спайковые нейронные сети, динамическая память.*

* Данная работа выполнена при поддержке РНФ, проект № 19-72-10114.

Введение

Паттерны спонтанной активности корковых нейронов, как правило, очень нерегулярны, демонстрируя пуассоновскую статистику интервалов между спайками в коротких промежутках времени и колебания частоты возбуждения в более длительных временных масштабах. Классическая теория, объясняющая происхождение нерегулярного поведения нейронов, использует парадигму приблизительного баланса между сильным возбуждением и торможением, которые в большинстве случаев компенсируют друг друга, оставляя активность сети обусловленной флуктуациями, которые периодически нарушают сбалансированные условия [1]. Асинхронные сбалансированные состояния с нерегулярной слабо коррелированной локальной активностью наблюдались в сетях реалистичных спайковых нейронов. Эти состояния можно назвать гомогенными, так как частоты возбуждения всех нейронов примерно равны и стационарны.

Тем не менее, введение сбалансированной парадигмы возбуждения-торможения само по себе не решает второй части проблемы изменчивости, поскольку оно все еще не объясняет, как сети быстрых спайковых нейронов могут генерировать флуктуации частоты в медленных временных масштабах. Эти колебания являются отличительной чертой состояния, обычно называемого частотным хаосом или гетерогенным состоянием [2] для описания как временной изменчивости частоты, так и неравномерного распределения частот по нейронам. Частотный хаос впервые наблюдали в моделях сетей частотных нейронов [3], явно продемонстрировав переход от регулярной к хаотической динамике. В отличие от этого ожидается, что сети спайковых нейронов в термодинамическом пределе всегда будут хаотичными. Тем не менее, вопрос о переходе от гомогенного к гетерогенному хаотическому режиму в спайковых сетях до сих пор остается дискуссионным, и потенциальное физическое объяснение может заключаться в том, что выше перехода как флуктуации нейронных входов, так и выходов становятся сильно окрашенными. В последнее время было предпринято много усилий, чтобы понять точные динамические механизмы, лежащие в основе частотного хаоса, и его возможную функциональную роль для нейронных вычислений. Было выявлено несколько сценариев, ведущих к возникновению частотного хаоса в реалистичных сетях спайковых нейронов. В частности, высокая изменчивость и медленная динамика частот были продемонстрированы в сетях с кластерными возбуждающими связями [4]. Было показано, что сильно гетерогенные хаотические состояния возникают в

разреженной случайной сети для сильных синаптических связей [2]. Наконец, наблюдается переход к частотному хаосу, когда время синаптической интеграции становится большим по сравнению с характерным временем нейронной динамики [5].

Считается, что частотный хаос играет важную роль в облегчении сложных вычислений, происходящих в мозгу [6], поскольку было показано, что он поддерживает флуктуации. в течение более длительного времени, что приводит к замедлению нейронной активности, связанной с поведением, обучением и памятью. Сети хаотических всплесков уже успешно обучены для выполнения вычислительных задач, таких как генерация сигналов, классификация входных данных или прогнозирование нелинейной динамики. Имея это в виду, разумно предположить, что использование гетерогенных, а не гомогенных хаотических состояний может улучшить вычислительные возможности сети. Действительно, во многих приложениях данные накапливаются в течение нескольких секунд, что требует сравнительно большой динамической памяти. В настоящем исследовании мы обращаемся к проблеме, могут ли медленные флуктуации частоты, наблюдаемые в гетерогенном хаотическом состоянии, служить основой для такой динамической памяти.

Постановка задачи

Рассмотрим сеть из N тета-нейронов, динамика которой определяется выражением

$$\frac{d\theta_j}{dt} = (1-\cos\theta_j) + I_j(1+\cos\theta_j), \tag{1}$$

где θ_j – локальные фазовые переменные, связанные с соответствующими мембранными напряжениями соотношением $V_j = \tan(\theta_j/2)$. Входные токи Ij состоят из двух членов $I_j = I_b + s_j$, где I_b обозначает постоянный ток смещения, а s_j представляет собой синаптический ток. Говорят, что нейрон j произвел спайк, когда его фаза пересекает значение $\theta_j = \pi$. Спайки фильтруются двойными экспоненциальными синапсами вида

$$\frac{dr_j}{dt} = -\frac{r_j}{\tau_d} + h_j, \tag{2}$$

$$\frac{dh_j}{dt} = -\frac{h_j}{\tau_r} + \frac{1}{\tau_r\tau_d}\sum_{t_j^p}\delta(t-t_j^p), \tag{3}$$

Параметры τ_r и τ_d обозначают время синаптического подъема и затухания соответственно, r_j – выходной ток синапса, а t_{jp} – время возбуждения

нейрона j. Общий синаптический ток, полученный нейроном j, определяется выражением

$$s_j = g\sum_{k=1}^{N} A_{jk} r_k, \tag{4}$$

где g – сила связи, A_{jk} – элементы матрицы смежности, определяющие структуру синаптических связей.

Сначала рассмотрим разреженную случайную сеть с вероятностью связности $p = 0{,}1$. Для простоты мы не разделяем нейроны на возбуждающие и тормозные пулы и получаем силу связи каждой ненулевой связи из распределения Гаусса с нулевым средним и дисперсией $(Np)^{-1}$. Вместе со слегка отрицательным током смещения $I_b = -0{,}001$ это обеспечивает баланс между возбуждением и торможением, так что общая активность сети определяется флуктуациями, а не средним значением.

Для изучения коллективной динамики сети мы возбудили 10 произвольных нейронов и смоделировали активность сети в течение $t = 20$ с. Постоянные времени синаптического подъема и спада фиксированы на $\tau_r = 2$ мс и $\tau_d = 20$ мс, а сила связи g используется в качестве управляющего параметра. Обнаружено, что если сила связи превышает некоторое критическое значение g_c, хаотическая самоподдерживающаяся активность выходит из состояния покоя. Для сил связи, немного превышающих порог, сетевая активность является разреженной, нерегулярной и слабо коррелированной, как показано на рис. 1 для $g = 0{,}3$. Цепочки спайков отдельных нейронов являются субпуассоновскими с усредненной по сборке частотой возбуждения 3,74 ± 1,24 Гц, а соответствующие распределения интервалов между спайками характеризуются средним коэффициентом вариации 0,81 ± 0,13.

Дальнейшее увеличение силы связи приводит к значительным изменениям состояния сети. Так, при $g = 1$ более сильная связь не только увеличивает среднюю частоту возбуждения до 18,14 ± 6,96 Гц, но и вызывает переход к так частотному хаосу, когда частота возбуждения нейронов демонстрирует медленные колебания. На уровне динамики спайков характерный эффект заключается в том, что нейроны имеют тенденцию генерировать всплески спайков, чередующиеся с длительными периодами покоя. Также отметим, что в гетерогенном режиме динамика отдельных нейронов становится более коррелированной по сравнению с гомогенным состоянием.

Помимо увеличения силы связи, другой сценарий, о котором ранее сообщалось, вызывающий переход к частотному хаосу, основан на увеличении характерного синаптического времени. Чтобы проверить такой сценарий в нашей модели, мы фиксируем силу связи на уровне $g = 0{,}5$ и варьи-

руем время затухания синапса τ_d. Хотя средняя частота возбуждения заметно не меняется и составляет ≈ 8 Гц для любого $\tau_d > 20$ мс, средний коэффициент вариации для интервалов между спайками заметно растет с синаптическим временем.

До сих пор мы рассматривали только сети со случайной топологией соединения. Теперь разделим сеть на $M = 5$ равных групп и перемонтируем возбуждающие связи таким образом, чтобы связность внутри каждого группового вывода стала больше, чем связность между группами p_{out}. Коэффициент кластеризации $R = p_{in}/p_{out}$ вводится для измерения степени кластеризации, при этом значение $R = 1$ соответствует однородной случайной сети. Гетерогенная активность и самая высокую изменчивость наблюдаются при промежуточной степени кластеризации $R \sim 4$. В то время как средний коэффициент вариации лишь немного превышает 1, его стандартное отклонение примерно такое же, что свидетельствует о наличии значительного числа нейронов с $CV \approx 2$ и выше. Среднее время корреляции также достигает максимума при промежуточных степенях кластеризации и достигает нескольких сотен миллисекунд. Проявление гетерогенной нерегулярной активности для сетей с промежуточной кластеризацией аналогично двум предыдущим сценариям: нейроны имеют тенденцию генерировать всплески спайков. Однако локальные всплески имеют тенденцию коррелировать внутри кластеров, что вызывает выраженные медленные колебания активности кластеров.

Модельная задача

После подробного изучения динамики сети мы исследуем связь между ее внутренней активностью и вычислительными возможностями, в частности, ее способность служить в качестве сети с динамической памятью. Для этого обучим сеть выполнять простую вычислительную задачу задержки, определяемую следующим образом: сеть получает один вход в виде последовательности всплесков и должна указать, получила ли она всплеск или нет в течение периода заданной продолжительности. В частности, сеть должна ответить «1», если она получила хотя бы один всплеск в течение последних τ миллисекунд, и «0» в противном случае. Максимальное значение задержки τ, при котором сеть показывает достаточную точность, дает разумную оценку времени жизни ее динамической памяти.

В качестве входного сигнала используется пуассоновская последовательность импульсов с частотой $\lambda = 1$ Гц. Чтобы подать вход в сеть, сигнал (4), полученный каждым нейроном, изменяется на

$$s_j = g\sum_{k=1}^{N} A_{jk} r_k + g_{inp} u_j r_{inp}, \quad (5)$$

где g_{inp} – входное усиление, веса u_j выбираются независимо из равномерного случайного распределения [−1; 1], а r_{inp} — входной синаптический ток, определяемый тем же набором уравнений, что и уравнения (2), (3). Выход сети рассчитывается как

$$r_{out} = \sum_{j=1}^{N} w_j r_j, \quad (6)$$

настроив выходные веса w_j для обучения сети выполнению требуемой задачи. Ответ сети считается как «1», если его выход превышает 1/2, и как «0» в противном случае.

Описанный подход соответствует классической вычислительной структуре резервуарных вычислений, методу машинного обучения, основанному на машинах с жидкостным и эхо-состоянием [7, 8] для решения задач, использующих отклик динамического система, называемая резервуаром, на определенный вход, имеющий выход, генерируемый путем линейного объединения состояний считывающих узлов. Резервуарные вычисления имеют преимущество эффективного процесса обучения, поскольку обучаются только считываемые веса, влияющие на выходные данные, в то время как входные веса и веса внутри резервуара остаются неизменными. При обучении выходных весов w_j мы использовали метод наименьших квадратов или рекурсивный алгоритм наименьших квадратов [9]. Оба метода дали похожие результаты, и мы предпочли метод наименьших квадратов, так как он был быстрее. После некоторого периода обучения t_{train} производительность сети оценивалась в течение тестового периода t_{test} = 100 с. Для характеристики производительности сети измерялась ошибка

$$\varepsilon = \varepsilon_0 \nu_0 + \varepsilon_1 \nu_1, \quad (7)$$

где ν_0 и ν_1 — доли ложных выходных сигналов, равных нулю или единице соответственно, а ε_0 и ε_1 — веса ошибок, заданные таким образом, что постоянный выход либо нуля, либо единицы приводит к суммарной ошибке $\varepsilon = 1$. Сеть затем производительность P оценивается как величина, обратная ошибке $P = 1/\varepsilon$.

Чтобы решить проблему увеличения времени жизни динамической памяти сети, мы обучили ее выполнять задачу задержки для разных значений задержки τ и проанализировали производительность P. Результаты, представленные на рис. 1, показывают производительность с точки зрения задержка для нескольких различных конфигураций сети. В частности, мы исходили из сети со слабыми и быстрыми синапсами и без кластеризации свя-

зей ($g = 0{,}5$, $\tau_d = 20$, $R = 1$), которая допускает однородное состояние. Оптимальная производительность $P \approx 15$ достигается при задержке $\tau \approx 200$ мс. При малых задержках $\tau < 100$ мс производительность сети низкая, так как она не успевает отреагировать на стимул. При больших задержках производительность быстро падает и достигает половины максимального значения при $\tau \approx 500$ мс. Это указывает на то, что динамическая память сети длится около 0,2 с.

Рис. 1. Производительность сети P в зависимости от задержки τ.
Сплошная линия с кружками: сеть в однородном состоянии; пунктирная линия с квадратами: сеть с сильными синапсами ($g = 2$); штрихпунктирная линия со звездочками: сеть с кластерными связями ($R = 4$); пунктирная линия с ромбами: сеть с медленными синапсами ($\tau_d = 60$ мс); толстая пунктирная линия с ромбами: сеть с медленными внутренними синапсами ($\tau_d = 60$ мс), но быстрыми входными синапсами ($\tau_{d,inp} = 20$ мс)

Далее мы увеличили силу синапсов до $g = 2$ и проверили, улучшит ли это производительность сети. Для такой сильной связи последовательности спайков демонстрируют гораздо более длительное время корреляции (около 250 мс), что интуитивно предполагает гораздо более длительную

динамическую память. Удивительно, однако, что усиление синапсов изменило производительность сети лишь немного, а наблюдаемая динамическая память все еще составляла около 0,25 с. Мы также изучили влияние кластеризации с $R = 4$, что соответствует максимальному времени корреляции около 230 мс. Это привело к некоторому улучшению производительности сети, которая становится оптимальной при $\tau = 300$ мс и падает вдвое при $\tau = 600$ мс. Таким образом, время жизни динамической памяти в кластеризованной сети незначительно увеличивается по сравнению с сетью в однородном состоянии и достигает 0,3 с.

Наконец, мы рассмотрели сценарий с участием медленных синапсов, увеличив время синаптического распада до $\tau_d = 60$ мс. Этот подход наиболее сильно повлиял на динамическую память сети. Мы обнаружили, что производительность сети действительно существенно улучшилась, при этом плоский максимум $P \approx 30$ достигается на широком интервале $\tau = 500 - 1000$ мс. При больших задержках производительность сети быстро ухудшается, так что динамическая память сети может быть оценена как 1 с. Мы проверили также, может ли расширение динамической памяти быть вызвано изменением самого раздражителя, так как при более длительном синаптическом времени она состоит из более длинных импульсов. Для этого мы уменьшили время затухания входных синапсов только до $\tau_d = 20$ мс и сохранили внутренние синапсы с $\tau_d = 60$ мс, заметив, что производительность сети незначительно снизилась, но все еще существенно превосходит сеть с быстрыми синапсами. Действительно, время жизни динамической памяти в этом случае по-прежнему составляет около 1 с.

Выводы

Мы рассмотрели три различных сценария возникновения частотного хаоса в разреженной сети спайковых нейронов и изучили их влияние на вычислительную способность сети для выполнения простой задачи динамической памяти. Признаком частотного хаоса являются медленные колебания частот отдельных нейронов, которые вводят новые временные масштабы, более длинные, чем те, которые связаны с динамикой синхронизации спайков. Были рассмотрены три типовых сценария перехода к тарифному хаосу. Первый сценарий предполагает усиление синаптической связи, второй основан на замедлении динамики синапсов, а третий наблюдается при определенной степени кластеризации синаптических связей. Хотя обо всех трех сценариях сообщалось ранее, они по-прежнему рассматривались отдельно для разных сетевых моделей, и настоящее исследование впервые предоставляет универсальную модель, в которой все сценарии можно

наблюдать и сравнивать, изменяя различные системные параметры, такие как связь сила, время синаптического распада и степень кластеризации.

Было показано, что на микроскопическом уровне отдельных последовательностей нейронных спайков все три сценария дают очень похожие характеристики. Тем не менее, вычислительные возможности базовых режимов оказались совершенно разными, по крайней мере, при выполнении простых задач, связанных с задержкой. Мы показали, что динамическая память сети в гетерогенном состоянии существенно зависит от механизма, порождающего это состояние. А именно, для сценариев с сильными синапсами или кластеризацией связей продолжительность динамической памяти остается примерно такой же, как и в гомогенном состоянии. Напротив, сценарий с участием медленных синапсов приводит к существенному увеличению продолжительности динамической памяти, которая достигает значений выше 1 с.

Выявление механизмов, которые позволяют кортикальным сетям выполнять вычислительные задачи в масштабе секунд, в то время как локальная активность нейронов разворачивается в масштабе миллисекунд. Уже было показано, что простое увеличение размера сети очень мало влияет на время жизни памяти, поскольку оно масштабируется только как логарифм размера сети [10]. Таким образом, основная проблема должна быть решена с точки зрения поиска подходящего механизма, который наделяет динамику сети длительными временными масштабами. Наше исследование, тем не менее, указывает на дополнительную проблему в том смысле, что простое присутствие более длинных временных масштабов в последовательности спайков может не гарантировать более длительную память.

Список литературы

1. Van Vreeswijk C., Sompolinsky H. Chaos in neuronal networks with balanced excitatory and inhibitory activity // Science. 1996. V. 274 (5293). P. 1724–1726.

2. Ostojic S. Two types of asynchronous activity in networks of excitatory and inhibitory spiking neurons // Nature Neuroscience. 2014. V. 17 (4). P. 594–600.

3. Sompolinsky H., Crisanti A., Sommers H.-J. Chaos in random neural networks // Physical Review Letters. 1988. V. 61 (3). P. 259.

4. Litwin-Kumar A., Doiron B. Slow dynamics and high variability in balanced cortical networks with clustered connections // Nature Neuroscience. 2012. V. 15 (11). P. 1498–1505.

5. Kadmon J., Sompolinsky H. Transition to chaos in random neuronal networks // Physical Review X. 2015. V. 5. P. 041030.

6. Jaeger H. The «echo state» approach to analysing and training recurrent neural networks-with an erratum note // German National Research Center for Information Technology GMD Technical Report. 2001. V. 148 (34), P. 13.

7. Maass W., Natschl T., Markram H. Real-time computing without stable states: a new framework for neural computation based on perturbations //Neural Computations. 2002. V. 2560. P. 2531–2560.
8. Haykin S. Adaptive filter theory // Prentice Hal, Upper Saddle River, NJ, 2002.
9. Wallace E., Maei H.R., Latham P.E. Randomly connected networks have short temporal memory // Neural Computations. 2013. V. 25 (6). P. 1408–1439.

Р.А. КОНОНОВ, О.В. МАСЛЕННИКОВ
Институт прикладной физики им. А.В. Гапонова-Грехова, Нижний Новгород
Национальный исследовательский Нижегородский государственный университет им. Н.И. Лобачевского
olmaov@ipfran.ru

ПОПУЛЯЦИОННАЯ ДИНАМИКА В РЕКУРРЕНТНЫХ НЕЙРОННЫХ СЕТЯХ: ОБУЧЕНИЕ С ПОДКРЕПЛЕНИЕМ ЗАДАЧАМ КОГНИТИВНОЙ НЕЙРОНАУКИ*

В работе представлена рекуррентная нейронная сеть, которая методами обучения с подкреплением обучена решать задачу, инспирированную экспериментом в области когнитивной нейронауки, - перцептивного принятия решения с контекстом. Изучены динамические механизмы выполнения сетью целевой функции. Выделены функциональные кластеры нейронов, специализированные на выполнении отдельных этапов испытаний и выделении различных признаков входных и выходных сигналов.

Ключевые слова: *рекуррентная нейронная сеть, когнитивная задача, обучение с подкреплением, нелинейная динамика.*

Введение

В последнее десятилетие для моделирования в вычислительной нейронауке всё чаще привлекаются методы машинного обучения [1, 2, 3, 4]. При этом чаще всего применяются методы обучения с учителем, которые подразумевают настройку весовых коэффициентов на основе минимизации функции ошибок, вычисляемой на основе разницы между выходами сети и целевыми сигналами. Для обучения сети методами данного класса необходимо заранее указать пары «входной стимул – выходной отклик».

* Данная работа выполнена при поддержке гранта РНФ 23-72-10088.

Методы другого класса – обучения с подкреплением – идеологически ближе к натурным экспериментам. Обучение в них основывается на получении награды за правильные решения, таким образом, алгоритм обучения с подкреплением ищет правильную стратегию выбора выходных откликов в ответ на входящие стимулы для максимизации накопленной награды (подкрепления).

В данной работе рекуррентная искусственная нейронная сеть с кусочно-линейной функцией активации обучена когнитивной задаче в рамках обучения с подкреплением. Динамика обученной сети исследована с помощью анализа проекций в пространстве главных компонент. С помощью кластеризации нейронов по рекуррентным весам выделены ключевые кластеры сети.

Обучение с подкреплением

Термин «подкрепление» восходит к биологическим экспериментам по изучению рефлексов, на основе которых постепенно сформировалась теория обучения с подкреплением как самостоятельное направление машинного обучения. Основная идея обучения с подкреплением – это концепция агента, действующего в среде. Под средой подразумевается система, генерирующая набор сенсорных сигналов и сигнал награды для агента, а под агентом – система принятия решений, способная к обучению на основе награды. Конкретный алгоритм обучения, который использовался в данной работе – проксимальное обновление стратегий. Для понимания алгоритма важно указать на общепринятые в обучении с подкреплением обозначения. Текущее состояние среды обозначается $\boldsymbol{s}_t \in \mathbb{R}^n$, в нашей задаче состояние среды полностью характеризуется сенсорными сигналами, но в общем случае может содержать и скрытые от агента параметры. Действие, которое предпринимает агент в ответ на состояние среды $\boldsymbol{s}_t$, обозначается как $a_t \in \mathbb{N}$. Награда, полученная агентом от среды за данное действие, – $r_t \in \mathbb{R}$.

Рис. 1. Иллюстрация концепции агента в среде

Стратегия агента обозначается π_θ, где θ – вектор параметров. Стратегия – это правило, по которому задается вероятность выбора действия a в состоянии s_t.

Целевая оптимизация весов происходит за счёт градиентного спуска по функции потерь следующего вида:

$$L^{actor}(s,a,\theta,\theta_k) = min\left(\frac{\pi_\theta(a|s)}{\pi_{\theta_k}(a|s)}A^{\pi_{\theta_k}}(s,a), \qquad g(\epsilon, A^{\pi_{\theta_k}}(s,a))\right)$$

$$g(\epsilon, A) = \begin{cases}(1-\epsilon)A, & A \geq 0\\ (1+\epsilon)A, & A < 0\end{cases}$$

где ϵ – гиперпараметр.

Основную роль в поиске стратегии играет оценка преимущества A, представляющего собой разницу между суммой наград, которые будут получены, если следовать текущей стратегии, и суммой наград, которые будут получены, если следовать предыдущей. Таким образом, если новая стратегия приводит к большим наградам, она закрепляется, а если наоборот – ослабляется.

Для оценки предыдущей стратегии используется нейронная сеть, называемая критиком, а сеть, принимающая решения, называется исполнителем. Функция потерь критика имеет вид,

$$L^{critic} = \sum_t (G_t - V_t)^2,$$

где G_t – сумма наград текущей стратегии, V_t – выход критика.

Взятие минимума в правой части (1) играет роль ограничителя, не позволяющего стратегии измениться слишком кардинально.

Рис. 2. Иллюстрация ограничения функции потерь. Зависимость функции потерь исполнителя от отношения новой и старой стратегий

В конечном итоге обновление весов модели происходит путём градиентного спуска по функции потерь вида:

$$Loss = Loss^{actor} + c_{vf} * Loss^{critic},$$

где c_{vf} – гиперпараметры

Оценка суммы наград, которую получит сеть-исполнитель, производится по формуле:

$$G_t = \gamma r_{t+1} + \cdots + \gamma^{T-t+1} r_{T-1} + \gamma^{T-t} V(s_T),$$

где T – длина окна, на котором собираются данные для обновления оценки, γ – коэффициент дисконтирования награды

Когнитивная задача перцептивного выбора с контекстом

В настоящей работе целевая задача основана на следующем прототипном эксперименте [1]. Обезьянам демонстрировали экран с двигающимися точками двух возможных цветов, и учили распознавать, какого цвета точек больше или в какую сторону движется больше точек. При этом обращать внимание они должны были только на один признак, на который указывали специальные сигналы контекста. Эксперимент проводился как на поведенческом, так и параллельно на нейрофизиологическом уровнях.

Рис. 3. Сенсорные сигналы в течение 4 разных испытаний

В данной работе использована упрощённая модель этой задачи. Когнитивному агенту-нейросети предъявляется 7 сенсорных сигналов. Пример сигналов представлен на рис. 3.

x_1 – сигнал фиксации. Он равен 1 в течении всего испытания и зануляется только в момент принятия решения.

x_2, x_3 – пара стимулов для контекста A. В случае без шума $x_2 + x_3 = 1$, а когерентность пары стимулов $coh = (x_3 - x_2) * 100$.

x_4, x_5 – аналогичная пара стимулов для контекста B.

x_6, x_7 – соответственно сигналы контекстов A и B, только один из них, соответствующий текущему контексту одновременно равен 1, а другой равен 0.

Испытание делится на 4 периода.

1. Период фиксации, в течение которого подаётся только сигнал фиксации, равный 1.
2. Период стимулов, когда агенту демонстрируются стимулы.
3. Период задержки, когда агенту вновь демонстрируется только сигнал фиксации.
4. Период принятия решения, когда обнулением сигнала фиксации от агента ожидается его решение в виде действия. В данной среде у агента есть всего три действия: выбор не сделан, выбор 1 и выбор 2.

Награда агенту выдается в ответ на предпринятое им действие в период принятия решения если это действие совпадает с номером доминирующего стимула текущего контекста.

Обучаемая модель

Вышеописанной задаче обучена искусственная нейронная сеть-исполнитель. Для работы алгоритма необходима вторая сеть-критик. Архитектурно исполнитель и критик совпадают, различается только выходная размерность, однако это две отдельные нейронные сети, которые обучаются одновременно.

Рис. 4. Полная схема агента

$$\begin{cases} \boldsymbol{h}_t^{actor} = relu(\boldsymbol{x_t} U_{actor}^T + \boldsymbol{h}_{t-1}^{actor} W_{actor}^T) \\ \boldsymbol{out}_t^{actor} = \boldsymbol{h}_t^{actor} O_{actor}^T \end{cases}$$

$$\begin{cases} \boldsymbol{h}_t^{critic} = relu\left(\boldsymbol{x_t} U_{critic}^T + \boldsymbol{h}_{t-1}^{critic} W_{critic}^T\right) \\ V_{\boldsymbol{t}} = \boldsymbol{h}_t^{critic} O_{critic}^T \end{cases}$$

$$relu(\boldsymbol{y})_j = \begin{cases} 0, & y_j \le 0 \\ y_j, & y_j > 0 \end{cases}$$

$$\boldsymbol{h}_t \in \mathbb{R}^{50} - \text{вектор активности сети}$$

$$\boldsymbol{x_t} \in \mathbb{R}^7, 0 < x_{tj} < 1 - \text{вектор сенсорных сигналов}$$

$$U_{actor}, U_{critic} \in \mathbb{R}^{50\times 7} \quad W_{actor}, W_{critic} \in \mathbb{R}^{50\times 50}$$

$$O_{actor} \in \mathbb{R}^{3\times 50} \quad \boldsymbol{out}_t \in \mathbb{R}^3; \quad O_{critic} \in \mathbb{R}^{1\times 50} \quad V_t \in \mathbb{R}^1$$

Выходы исполнителя интерпретируются как ненормированные логарифмические вероятности и после нормировки вида

$$P_j = out_j - ln \sum_{j=0}^{3} e^{out_j}; \qquad \sum_{j=0}^{3} e^{P_j} = 1$$

представляют вероятностное распределение, на основе которого случайно выбирается действие агента. Таким образом, в систему вносится элемент случайности, характерной для обучения с подкреплением.

Выход критика – это ценность состояния среды.

Обученная сеть

Вышеописанная модель была обучена в течение 300 000 испытаний. При обучении варьировалась длительность периодов испытания, а набор используемых значений когерентности был ограничен 6 возможными величинами. Для обучения использовалась реализация алгоритма в пакете Stable-Baselines3-contrib (При значениях гиперпараметров $\epsilon = 0{,}2$; $\gamma = 0{,}99$; $c_{vf} = 0{,}5$), модифицированная для работы с полносвязными рекуррентными сетями. Для градиентного спуска использовалась алгоритм Adam (При значениях гиперпараметров $\beta_1 = 0{,}9; \beta_2 = 0{,}999$; lr=0,001).

Обученная сеть демонстрирует на уровне генерации выходных откликов в ответ на входные стимулы сходное поведение с испытуемыми животными в прототипном эксперименте. На рис. 5 отображена зависимость вероятности выбора обученной сетью ответа 2 от когерентности испытаний в случае активации первого и второго контекста соответственно. Наблюдается сильная зависимость от когерентности стимулов текущего контекста

и слабую зависимость от когерентности стимулов альтернативного контекста. Полученные характеристики схожи с психофизическими кривыми при натурных экспериментах с животными.

Заметим, что обученная сеть показывает хорошую точность на всём диапазоне значений когерентности, включая те, которые не были представлены при обучении, что говорит о приобретенном свойстве обобщения.

Рис. 5. Вероятность выбора обученной сетью ответа 2
от когерентности испытания в случае контекста A и контекста B

Рис. 6. Матрица смежности обученной сети W_{actor} и дендрограмма,
иллюстрирующая иерархическую структуру сети.
На дендрограмме пронумерованы ключевые кластеры сети

Кластеризация нейронов

Для анализа структуры и активности, лежащей в основе функционирования сети, нейроны были кластеризованы по исходящим рекуррентным весам с помощью агломеративного алгоритма. Изначально каждый нейрон представляет собой отдельный кластер, после чего кластеры, дисперсия которых после объединения минимальна последовательно объединяются. Ход алгоритма показан на дендрограмме на рис. 6. Среди выделенных 10 кластеров обнаружено три ключевых. Отключение любого из них приводит к нарушению индуцированной стимулом динамики, а сеть только из этих кластеров динамику сохраняет. Установлена роль кластеров в формировании выходов сети:

1) отвечает за отклик при контексте A;
2) отвечает за отклик при контексте B.

Активность нейронов

Установлена зависимость активности кластеров в течение испытаний с разным знаком когерентности. Кластеры 2 и 1 более активны в течение испытаний с положительной когерентностью, а кластер 3 для испытаний отрицательной когерентностью.

Рис. 7. Активность нейронов сети в течение последовательности из четырёх испытаний. Сенсорные сигналы (состояние среды) приведены на графике справа (отдельно выделен сигнал фиксации). Параметры испытаний в таблицах справа

Активность сети в течение последовательности из четырёх испытаний приведена на рис. 7. Ключевые кластеры выделены сверху. Внутри кластеров также выделены группы нейронов активные в разные периоды испытания. Например, в течение второго испытания внутри второго кластера половина нейронов активна равномерно в период подачи стимулов и задержки, а другая половина больше активна в период подачи стимулов.

Выводы

Искусственная нейронная сеть с кусочно-линейной функцией активации была обучена когнитивной задаче перцептивного выбора с контекстом методом обучения с подкреплением «проксимальное обновление стратегий».

Обученная сеть демонстрирует целевую функцию преобразования входов в выходы, схожую с поведенческой активностью в натурных экспериментах.

Изучена структура весов обученной сети и популяционная динамика рекуррентной нейросети при решении целевой задачи. Выделены кластеры нейронов, отвечающие различным аспектам функциональной активности сети.

Список литературы

1. Mante, V., Sussillo, D., Shenoy, K. Context-dependent computation by recurrent dynamics in prefrontal cortex // Nature. 2013. Vol. 503. P. 78.
2. Pugavko M.M., Maslennikov O.V., Nekorkin V.I. Multitask computation through dynamics in recurrent spiking neural networks // Scientific Reports. 2023. Vol. 13. P. 3997.
3. Масленников О.В., Пугавко М.М., Щапин Д.С., Некоркин В.И. Нелинейная динамика и машинное обучение рекуррентных спайковых нейронных сетей // УФН. 2022. Т. 192 С. 1089.
4. Song H.F., Yang G.R., Wang X.J. Reward-based training of recurrent neural networks for cognitive and value-based tasks // Elife. 2017. Vol. 6. P. e21492.

А.К. КРЫЛОВ
Институт психологии РАН
neuru@mail.ru

НЕЛОГИЧНОСТЬ И КУЛЬТУРОСПЕЦИФИЧНОСТЬ МЫШЛЕНИЯ ПРИ РЕШЕНИИ ЛОГИЧЕСКИХ ЗАДАЧ*

Рассматриваются различия логики мышления и математической логики. Отмечается зависимость логики мышления от типа культуры: западной и незападной, соответствующих менталитетов. Логическое мышление – процесс, разворачивающийся при решении логических задач, – зависит от воспитания и среды, существенно отличается от математических принципов логического вывода.

Ключевые слова: *ментальность, мышление, логика, культура.*

Введение

Вопрос о соотношении человеческого мышления и законов логики сначала считался вопросом философии. Аристотель утверждал, что человек является существом рациональным. В конце 19-го века британские эмпирицисты и немецкие логицисты утверждали, что законы логики являются приемлемым обобщением человеческого мышления. В частности, Кант считал логику врожденным свойством человеческого мышления. На рубеже 19-го и 20-го веков Гуссерль и Фреге выступили против такого «психологизма», в защиту объективности логики. С развитием психологии к середине 20-го века изучение мышления стало ее разделом. Пиаже, рассматривая этапы развития мышления ребенка, утверждал, что при взрослении у человека развивается (сама собой) способность к контекстно-свободным дедуктивным рассуждениям на уровне элементарной логики 1-го порядка [1]. Далее последовал этап экспериментальных исследований логики человеческих рассуждений. В таких психологических экспериментах с использованием различных логических задач были найдены отличия человеческой логики от математической. Было обнаружено, что человек в рассуждениях использует «эвристики» для совершения логического вывода в ситуациях с неопределенностью, при неполной информации, и в сложных ситуациях [2, 3]. Также было обнаружено наличие трендов (bias), предпочтений при принятии решений, обнаруживающих себя при повторении опыта.

* Работа выполнена по заданию НИР №0138-2023-0002.

С учетом обнаруженных отклонений человеческого мышления от рационального (математической логики), в 1957 Саймон (Simon) ввел для описания человеческой логики понятие «ограниченная рациональность» (bounded rationality) [2].

В 70-х годах Kahneman и Tversky начали разрабатывать программу исследования «эвристик и предпочтений» (heuristics and biases). Они сделали вывод, что человек плохо владеет основами статистики и не следует считать его «рациональным» в строгом смысле слова [4–6].

В 1981 Cohen, задавшись вопросом что считать иррациональным, пришел к выводу, что люди все же рациональны, и даже интуиция – рациональна [7]. Однако продолжали накапливаться экспериментальные данные, свидетельствующие об особенностях человеческой логики. В 1989 Evans показал, что люди плохо владеют правилом вывода modus tollens [8]. Далее, было показано, что человек использует индуктивный и дедуктивный вывод, по крайней мере, в некоем виде [9].

Также, было замечено, что даже небольшое обучение человека основам математической статистики способствует принципиально лучшему выполнению логических задач [10]. Bringsjord считает [11], что тезис Пиаже о том, что человек овладевает уровнем формально-логических операций, подтверждается если людей учить логике также как учат чтению и арифметике. Выдвинута гипотеза о том, что человек осваивает логику (математическую) благодаря обучению на специальном курсе логики, а не потому, что логика является врожденной способностью мышления, как это считал Кант.

В 90-х годах была сформирована программа исследований «адаптивный набор инструментов» (adaptive toolbox) как развитие программы «эвристик и предпочтений» [12]: систематические ошибки и тренды в человеческой логике рассматриваются теперь не как недостатки, а как особенности; за основу взята концепция Simon «ограниченная рациональность» [2], причем ограничения эти рассматриваются не как следствие ограничений человеческого мозга, а как следствие большей практической успешности быстрых и экономных эвристик по сравнению с полностью рациональными стилями мышления.

В исследованиях рассуждений вслух при решении задач показано, что мышление как процесс обладает свойством недизъюнктивности [13], который возможно описать в системной психофизиологии как механизм временной дедифференциации, происходящий в процессе мышления при смене одной гипотезы на другую, и является следствием системной структуры индивидуального опыта [14].

В настоящее время исследуются преимущества «нелогичности» человеческого мышления над строго логичным стилем рассуждений, а также особенности логики представителей западной и незападной культур.

Обнаруженные «нелогичности» в человеческой логике

1) Задача Wason

Один из самых известных эффектов, обнаруженный Peter Wason в 1966, рассматривается некоторыми исследователями как опровержение представлений Пиаже, доказательством того, что человек не владеет элементарной логикой и заключается в следующем. Испытуемому предъявляются 4 карты и сообщается логическое правило, определенное для этих карт, истинность которого он должен проверить, переворачивая минимально необходимые карты. Например, предъявляются карты «А», «К», «4», «7» и сообщается правило «если на одной стороне карты изображена гласная буква, то на другой стороне нечетное число». С т. зр. математической логики, для проверки этого правила необходимо перевернуть карты «А» и «7». Здесь речь идет о проверке истинности правила «p->q», где p – предикат гласной буквы, q – предикат четной цифры, поэтому математически правильным ответом будет выбор карт p и не-q. Однако, эксперименты показали, что выборы, делаемые испытуемыми, распределяются следующим образом: 46 % людей выбирают p и q (проверяют карты «А» и «4»), 33 % выбирают p, и только 4% выбирают математически верный выбор: p и не-q [15].

Однако, обнаружено, что если логически аналогичная задача дается испытуемым в более привычных к жизни терминах (карты: «Манчестер», «Шеффилд», «машина», «поезд»; правило: «в Манчестер я езжу на поезде»), то 80 % испытуемых дают логически верный ответ [16].

2) Проблема «THOG»

Предположим, существуют 4 типа объектов: счастливый додекаэдр, несчастливый додекаэдр, счастливый куб и несчастливый куб. Экспериментатор загадал один из атрибутов (счастливый либо несчастливый) и одну из форм (додекаэдр либо куб). Испытуемому сообщают правило: объект является GOKE если и только если, он имеет ту же форму что я загадал или тот же атрибут, но не оба сразу. Далее сообщают, что несчастливый додекаэдр является GOKE и просят назвать другой GOKE если такой существует. Только 10% образованных испытуемых смогли дать правильный ответ: счастливый куб [17].

3) исключающее или

Предлагается следующее правило: «если на руках есть король, то есть и туз, или иначе, если на руках нет короля, то есть туз», и спрашивается «Какой можно сделать вывод?». Большинство испытуемых делают вывод, что «на руках есть туз», что неверно [18].

4) неверный силлогизм

Испытуемому предъявляются утверждения: «Все французы в этой комнате предпочитают пить вино», «Некоторые из пьющих вино в этой комнате являются гурманами», и спрашивается «Что следует из этих двух утверждений?». Многие делают вывод, что «некоторые французы в комнате являются гурманами», что неверно [19].

5) задача про «родильное отделение»

Задача предлагается следующая: «В городе есть 2 госпиталя. В большем ежедневно рождается 60 детей, в меньшем – 15», и вопрос: «в каком из госпиталей в течение года будет больше дней в которые 60 % и более процентов рождающихся будут мальчиками?». Треть испытуемых назвала меньший, треть – больший, и треть – оба. Хотя по закону больших чисел правильный ответ – больший [4].

6) неверное представление о понятии «случай»

Испытуемых спрашивали, какое распределение выпадений монет более вероятно: «О-Р-О-Р-Р-О» или «О-О-О-Р-Р-Р» (О − орел, Р – решка). Хотя обе цепочки событий статистически эквивалентны, испытуемые ошибочно полагают что первая, выглядящая более случайной по структуре, будет выпадать чаще [4].

Аналогично, известна «ошибка игрока в рулетку»: после того, как несколько раз подряд выпало «красное», игрок полагает, что вероятность выпадения «черного» повышается.

7) игнорирование априорной вероятности (prior probability)

Задача: «в городе 85 % машин – синие, 15 % − зеленые; свидетель аварии заявил на суде, что видел зеленую машину, но известно, что в темноте этот свидетель мог отличить синюю от зеленой лишь в 80 % случаев. Какова вероятность того, что в аварию попала зеленая машина?». Оказалось, что эту задачу испытуемые решают, не учитывая априорные вероятности (15 % / 85 %) [4, 5, 7].

8) тенденция, обусловленная поиском

Испытуемых спрашивали − «что более вероятно (в английском языке), что слово начинается с буквы R или что R является третьей буквой в слове?» Поскольку испытуемым было легче умозрительно обнаружить слова, начинающиеся с буквы R чем обнаружить слова с буквой R на третьем месте, они посчитали, что количество слов с буквой R на первом месте

выше, хотя на самом деле в словаре намного больше слов с буквой R в третьей позиции [5].

9) оценка вероятности конъюнкции

Вероятность конъюнкции двух событий m(A&B) не может превышать вероятности каждого из событий: m(A) m(B). Человек может нарушать это правило. Например, оценивая некоего персонажа Билла по тексту о нем, испытуемые дают большую оценку вероятности утверждению «Билл – бухгалтер и любит джаз» (A&B), чем вероятности утверждения «Билл любит джаз» (B) [6].

10) сверхуверенность в выбранном

Показано, что после того, как испытуемые совершают выбор, они оценивают вероятность правильности своего выбора слишком высоко [20].

11) парадокс сорита

Если одна песчинка не создает различия между «кучей» и «не кучей», значит и две песчинки, и три, и т.д., не способны создать «кучу» [21].

12) парадокс импликации

Импликация P=>Q верна, если P ложно, или если Q истинно. Импликация обычно читается как «Если P, то Q». Однако, импликации «Если 2 равно 3, то луна сделана из сыра» (P ложно) и «Если на Марсе есть жизнь, то у дроздов есть перья» (Q истинно), хотя и верны с т. зр. математической логики, но не выглядят логичными для человека [21].

13) парадокс подтверждения

Черные вороны обычно рассматриваются как положительное подтверждение утверждению «вороны – черны». Аналогично, не-черные не-вороны (например «белые пакеты») должны бы рассматриваться как положительное подтверждение утверждению «Не черные объекты не являются воронами». Хотя оба утверждения эквивалентны с т.зр. математической логики, существование «белых пакетов» не кажется человеку фактическим подтверждением того, что «вороны – черны» [21].

14) недедуктивный вывод

В традиционной логике все правила вывода являются дедуктивными, при этом истинность посылок гарантирует истинность следствия. Однако, человек также использует недедуктивный вывод, в котором истинность посылок не гарантирует истинность следствий: индукцию, порождающую обобщения частным случаям (если «дрозды – птицы» и «у дроздов есть перья», то «у птиц есть перья»); абдукцию, порождающую объяснения частным случаям (если «у птиц есть перья» и «у дроздов есть перья», то «дрозды – птицы»); аналогию (если «ласточки походи на дроздов» и «у дроздов есть перья», то «у ласточек есть перья») [21].

15) особенности транзитивного вывода

Испытуемым было предъявлено, что A>B, B>C, C>D, D>E, E>F, и эти правила они освоили верно. После чего, испытуемые уверенно определили, что B>E, но не смогли обнаружить, что B>D, C>E [22].

16) неопределенность

В отличие от классической математической логики, для человека известны следующие феномены в рассуждениях: значение термина меняется в зависимости от контекста и опыта (что означает слово «язык»?); значение составного термина несводимо к значениям компонентов; при оценке истинности утверждений используются значения промежуточные между истиной и ложью (т.е. нечеткие); оценка истинности утверждения может меняться со временем, по мере поступления уточняющей информации; противоречие не считается доказательством чего-либо; сам процесс рассуждений движется непредсказуемо; логика законченных рассуждений не всегда может быть потом сознательно восстановлена; процесс рассуждений целенаправлен, но не всегда ведется до конечной цели [21].

Подходы к формализации человеческой логики

Wang, критикуя как строго аксиоматические системы, так и полуаксиоматические системы, предлагает для моделирования человеческой логики использовать неаксиоматическую систему рассуждений [21].

В строго аксиоматических системах рассуждений предполагается, что знаний и ресурсов – достаточно; все необходимое встроено в готовую систему аксиом; запросы не имеют временных границ. Если же запрос требует информации, выходящей за систему аксиом, то это рассматривается не как ошибка системы, а как ошибка запросившего, т.е. ничего не предпринимается чтобы расширить возможности системы и адаптировать ее к среде.

В системах с немонотонной логикой, относящимся к полуаксиоматическим системам, строится гипотетический вывод («Твити может летать») из базовых положений («Птицы умеют летать») и фактов («Твити – птица»), и этот вывод пересматривается, когда появляются новые факты («Твити – пингвин»). Однако, в таких системах базовые положения и факты обычно неизменны, и не учитываются временные ограничения на принятие решений [23].

Нечеткая логика (полуаксиоматическая) рассматривает принадлежность объекта к категории с некоторой величиной принадлежности, однако не объясняет, откуда берется эта величина [21].

Многие обучающиеся системы способны к улучшению своего поведения, однако работают лишь в бинарной логике, в которой все делится на черное и белое, и настойчиво ищут оптимальное решение задач [24]. Хотя некоторые системы с эвристическим поиском способны искать субоптимальные решения при наличии ограничений по времени, они обычно не способны обучаться и учитывать вариации в ограничениях по времени [3].

Замечено, что «анализ изменения оценок вероятности утверждений в процессе логического вывода показывает, что они всегда уменьшаются, причем, как правило, существенно (за исключением случая, когда условная вероятность или вероятность равны 1), поэтому аксиоматический подход адекватен оперированию лишь с достоверным знанием» [25]. Вместо аксиоматического метода и правил вывода, предлагается семантический вероятностный вывод, оценки предсказания в котором, наоборот, всегда строго возрастают [25].

Западная и восточная логики мышления

Существует ряд свидетельств в пользу отличий логики мышления западноевропейской и восточноазиатской [26]. Мышление представителей западноевропейской культуры в большей степени считается сходным с формальной математической логикой.

В китайской диалектической эпистемологии трудно выделить базовые принципы, потому что даже сами правила оказываются изменчивы, а понятия имеют множество значений. Тем не менее, с этой оговоркой, некоторые аспекты удается выделить:

1. «Закон изменения». Реальность – это процесс, она не стоит на месте, она постоянно изменяется. Поэтому понятия, описывающие реальность не могут быть постоянны. (Это «противоречит» закону тождества A=A в западноевропейской логике).
2. «Принцип противоречия». Реальность не четка, она полна противоречий. Хорошее и плохое, старое и новое, сильное и слабое – сосуществуют во всем и находятся в гармонии. Изменения постоянны, поэтому постоянны и противоречия. (Допустимо A&~A). И противоположности составляют единое целое как Инь и Ян.
3. «Принцип холизма». Нет ничего отдельного, все соединено.

Таким образом, в восточном стиле мышления, предположительно, нарушаются законы Аристотелевой логики: закон идентичности, закон непротиворечия, закон исключенного третьего.

Такие предположения были сделаны [26], в частности, на основе исследований предпочтений поговорок людьми разных культур. Обнаружилось,

что представители восточной Азии более предпочитают диалектические поговорки, содержащие противоречия (например «опасайся своих друзей, а не своих врагов» – противоречит самому понятию «друг»), нежели представители западной Европы.

Подчеркивается [27], что нельзя сказать, что одна логика лучше другой, поскольку каждая из них адекватна соответствующей культуре и является эффективной в рамках реальной жизни людей, принадлежащих соответствующей культуре.

В культурологии выделено два типа культур: «западная» и «незападная», представители которых являются носителями соответствующего менталитета и стиля мышления. Для «западного» менталитета характерны дискретность логики мышления и формальная логика, аналитизм восприятия мира как набора обособленных объектов, рациональность принятия решений, что формируется в среде, предполагающей конкурентное решение задач; для «незападного» менталитета характерны континуальность логики мышления и терпимость к логическим противоречиям, холистичное восприятие мира как набора взаимосвязей, интуитивное принятие решений, что формируется в среде, предполагающей кооперативное решение задач [28, 29]. Соответственно, при рассмотрении типов мышления индивида возможно использование шкалы «аналитичность-холистичность»: индивиды аналитического типа ментальности предпочитают при решении задач расчленять объект на множество частей, воспринимать линейные изменения, выявлять противоречия, применять линейные алгоритмы при решении задач; в то время как индивиды холистического типа ментальности более склонны выделять взаимосвязи и уделять внимание контексту, сглаживать противоречия, применять циклические алгоритмы при решении задач или их симультанное решение [30–32].

Заключение

Из приведенного обзора видно, что человеческая логика отличается от математической. Более того, существуют индивидуальные различия во владении навыками математической логики даже у образованных людей. Существует гипотеза о том, что математическая логика – это навык, которому обучаются в учебном заведении, а не внутренне присущая особенность человеческого мышления. Логика человеческого мышления является индивидуально-специфичным и культуро-зависимым явлением. Математическая логика может быть связана с эволюцией западноевропейской культуры и ее классические построения не достаточны для описания процесса интуитивного решения задач и логики восточной ментальности.

Список литературы

1. Inhelder, B. and Piaget, J. The Growth of Logical Thinking from Childhood to Adolescence. Basic Books, New York, NY, 1958.

2. Simon, H. A. A Behavioral Model of Rational Choice, in Models of Man, 1957.

3. Simon, H. A. and Newell, A. Heuristic problem solving: the next advance in operations research. Operations Research, 6:1–10, 1958.

4. Kahneman, D., and Tversky, A., A subjective probability: A judgement of representativeness, Cognitive Psychology, vol.3, pp.430-454, 1972.

5. Kahneman, D., and Tversky, A., On the psychology of prediction, Psychological Review, vol.80. P. 237–251, 1973.

6. Tversky, A., and Kahneman, D., Judgements of and by representativeness, in D. Kahneman, P. Slovic and A. Tversky (eds.) Judgment Under Uncertainty: Heuristics and Biases, Cambridge University Press, 1982.

7. Cohen, L.J., Can human irrationality be experimentally demonstrated?, Behavioral and Brain Sciences, vol.4. P. 317–370, 1981.

8. Evans, J.St.B.T., Bias in Human Reasoning, Hillsdale, NJ: Erlbaum, 1989.

9. Nisbett, R.E. (ed.) Rules for Reasoning, Hillsdale, NJ: Erlbaum, 1993.

10. Nisbett, R.E., Reasoning, Abstraction, and the Prejudices of 20th Century Psychology, in Nisbett, R.E. (ed.)Rules for Reasoning, Hillsdale, NJ: Erlbaum, 1993.

11. Bringsjord, S., et al. In Defense of Logical Minds, in Proceedings of the 20th Annual Conference of the Cognitive Science Society (Hillsdale, NJ: Lawrence Erlbaum Associates). P. 173–178, 1998.

12. Gigerenzer, G., and Selten, R. (eds.), Bounded Rationality: The Adaptive Toolbox, MIT Press, Cambridge, Mass., 2001.

13. Брушлинский А.В. Субъект: мышление, учение, воображение. М.: Институт практической психологии; Воронеж: НПО «Модэк», 1996.

14. Крылов А.К. Формализация «недизъюнктивности» мышления по А.В. Брушлинскому: системно-эволюционное описание / Психология человека как субъекта познания, общения и деятельности / Отв. ред. В. В. Знаков, А. Л. Журавлёв. – М.: Изд-во «Институт психологии РАН», 2018. С. 85–91.

15. Wason, P. Reasoning. In New Horizons in Psychology. Penguin, Hammondsworth, UK, 1966.

16. Wason, P.C., and Shapiro, D. Natural and Contrived Experience in a Reasoning Task. Quarterly Journal of Experimental Psychology, vol. 23. P. 63–71, 1971.

17. Wason, P. C. Self-contradictions. In Thinking: Readings in Cognitive Science. Cambridge University Press, Cambridge, UK, 1977.

18. Johnson-Laird, P. and Savary, F. How to make the impossible seem probable. In Proceedings of the 17th Annual Conference of the Cognitive Science Society. P. 381–384, Hillsdale, NY, 1995.

19. Oakhill, J., et al. Believability and syllogistic reasoning. Cognition, 31:117–140, 1989.

20. Fischhoff, B., et al., “Knowing with certainty: The appropriateness of extreme confidence," Journal of Experimental Psychology: Human Perception and Performance, vol.3. P. 552–564, 1977.

21. Wang P. Cognitive Logic versus Mathematical Logic. Working Notes of the Third International Seminar on Logic and Cognition, Guangzhou, May 2004.

22. Frank M.J., et al. When logic fails: Implicit transitive inference in humans. Memory & Cognition, 33 (4). P. 742–750, 2005.

23. Reiter, R. Nonmonotonic reasoning. Annual Review of Computer Science, 2:147–186, 1987.

24. Michalski, R. Inference theory of learning as a conceptual basis for multistrategy learning. Machine Learning, 11:111–151, 1993.

25. Витяев Е.Е. Формальная модель работы мозга, вытекающая из принципа предсказания. // Модели когнитивных процессов (Вычислительные системы вып. 164). С. 3–62, Новосибирск, 1998.

26. Peng, K., & Nisbett, R. E. (1999). Culture, dialectics, and reasoning about contradiction. American Psychologist, 54, 741–754.

27. Kim, K., & Markman, A. B. Differences in fear of isolation as an explanation of cultural differences: Evidence from memory and reasoning. Journal of Experimental Social Psychology. vol 42. P. 350–364, 2006.

28. Александров Ю.И., Кирдина С.Г. Типы ментальности и институциональные матрицы: мультидисциплинарный подход // Социологические исследования. 2012. № 8. С. 3–12.

29. Апанович В.В., Александров Ю.И. Системное значение меж- и внутрикультурных ментальных вариаций / Вестник психофизиологии. 2021. № 1. С. 24–35.

30. Апанович В.В. и др. Различия мозгового обеспечения индивидуального, кооперативного и конкурентного поведения у субъектов с аналитическим и холистическим когнитивными стилями // Экспериментальная психология. 2016. Т. 9. № 2. С.5-22.

31. Апанович В.В., Арамян Э.А., Дольникова М.С., Александров Ю.И. Различия мозгового обеспечения решения аналитических и холистических задач // Психологический журнал. 2021. Т. 42. № 2. С. 45–60.

32. Апанович В.В., Тищенко А.Г., Арутюнова К.Р., Александров Ю.И. Способы решения аналитических и холистических задач // Экспериментальная психология. 2020. Т. 13. № 4. С. 52–71.

С.А. ПОЛЕВАЯ[1], А.В. КОВАЛЬЧУК[1], Е.В. ЕРЕМИН[1], С.А. ПЕРМЯКОВ[1], А.И. ФЕДОТЧЕВ[2], С.Б. ПАРИН[1]

[1]Национальный исследовательский Нижегородский государственный университет им. Н.И.Лобачевского

[2]Институт биофизики клетки РАН, Пущино

sofia.polevaia@fsn.unn.ru[1], fedotchev@mail.ru[2]

ЯЗЫК РИТМОГРАММ ДЛЯ ОТОБРАЖЕНИЯ ФУНКЦИОНАЛЬНЫХ СОСТОЯНИЙ ЧЕЛОВЕКА*

С помощью сверточной нейронной сети идентифицирован ряд функциональных состояний по данным кардиоритмограмм, полученных при использовании технологии событийно-связанной телеметрии ритма сердца. На примере кардиоспайков, присутствующих в данных ЭКГ лиц, перенесших инфекцию COVID-19, продемонстрирована эффективность подхода: на тестовом образце получено более 87 процентов точности в их автоматическом обнаружении. Это указывает на высокий потенциал использования кардиоспайков в качестве маркеров для COVID-специфических режимов вегетативной регуляции сердечного ритма. Сходный подход успешно применен для детектирования стресса и эмоциональной дезадаптации. Считаем, что данное исследование раскрывает перспективы использования нейросетевого подхода для расшифровки «языка ритмограмм» в различных функциональных состояниях.

Ключевые слова: *функциональные состояния, вариабельность ритма сердца, событийно-связанная телеметрия ритма сердца, стресс, COVID-19, эмоциональная дезадаптация.*

Введение

В кругу нейрофизиологов хорошо известно высказывание крупнейшего специалиста в области BCI Александра Яковлевича Каплана: «Регистрируемые нами биоэлектрические сигналы – ЭЭГ, ЭКГ и т.д. – не предназначены для передачи информации, а представляют собой шум от паровоза». Мы готовы согласиться с авторитетным мнением, но с одним уточнением: опытный машинист в былые времена по изменениям характера шума ухитрялся определить степень и природу вызывающих этот шум неполадок и

* Данная работа выполнена при частичной поддержке РНФ, грант № 22-18-20075.

зачастую предотвратить катастрофу. В настоящей работе мы постараемся продемонстрировать, что анализ паттернов кардиоритмограммы позволяет дифференцировать такие функциональные состояния человека, как стресс, эмоциональная дезадаптация и последствия заражения коронавирусом SARS-CoV-2 (COVID-19).

Необходимо подчеркнуть, что возможность рассматривать характерные особенности динамики вариабельности ритма сердца (ВРС) в качестве признаков различных функциональных состояний опирается на целый ряд теоретических оснований. Непосредственно информативность ВРС была впервые продемонстрирована в 60-х годах прошлого века, в связи с необходимостью контроля функционального состояния первых космонавтов [1]. В настоящее время эта методика существенно модернизирована и представляет собой комплексную технологию событийно-связанной телеметрии ритма сердца (ССТРС) [2].

Возможность использовать методологию современной нейрофизиологии для расшифровки языка кардиоритмограммы основана на системном подходе к анализу сложных паттернов. Так, сегодняшние знания о механизмах кодирования сенсорной информации, окончательно похоронившие курьёзные заблуждения о наличии так называемых болевых, тепловых и холодовых «рецепторов» кожи, основаны на доказательствах интегративного распределения импульсации по волокнам соответствующих нервов импульсации по афферентным волокнам соответствующих нервов [3]. Этот подход позволяет предложить гипотезу о сходстве принципов функционирования естественных нейронных сетей и искусственных беспроводных сенсорных сетей, соответственно, использовать для анализа паттернов кардиоритмограммы нейросетевые подходы [4].

Наконец, есть необходимость «договориться о терминологии». В нашем исследовании используются базовые положения предложенной С.А. Полевой и С.Ю. Петуховым теории информационных образов [4, 5]. Согласно этой теории, информационный образ – это отображение объектов и событий в пространстве признаков, сформированном на основе индивидуального и коллективного опыта. Отсюда язык – механизм трансляции информационных образов, в котором признаки записываются в форме кодов. Многообразие языков соответствует многообразию способов кодирования признаков (двоичный код, русский язык, дифференциальные уравнения и др.). Таким образом, кодировать – записывать информацию по правилам конкретного языка.

Эти положение легли в основу проведенного нами нейросетевого анализа специфических особенностей ритмограмм при различных функциональных состояниях.

Методы

В исследовании использовалась разработанная нами [2] технология ССТРС (рис. 1). В течение 8 лет была собрана экспериментальная база данных по более чем трём тысячам испытуемых, содержащая 113780 образцов характерных паттернов: 970 пациентов с подтвержденным клиническим диагнозом COVID-19 (110330 семплов − образцов кардиоспайков), 1535 испытуемых в верифицированных стрессогенных ситуациях (2930 образцов) и 520 волонтёров с повышенным уровнем эмоциональной дезадаптации (520 образцов).

Рис. 1. Принципиальная схема технологии ССТРС [2]

Результаты клинических анализов (данные МРТ, биохимические и иные функциональные показатели крови и др.), подтверждающие диагноз пациентов с COVID-19, были предоставлены клиниками системы ФМБА. Выявление характерных для последствий данного заболевания кардиоспайков на кардиоритмограмме осуществлялось в соответствии с патентом № 2779697 [6]. Уровень эмоциональной дезадаптации (УЭД) контролировался с помощью проективной методики согласно патенту № 2291720 [7] и выявлялся в соответствии с патентом № 2772185 [8]. Верификация эпизодов острого стресса осуществлялась в соответствии с положениями трёхкомпонентной теории нейрохимических механизмов стресса [9, 10] и в соответствии с патентами № 129680 и 2531443 [11, 12].

Для обучения нейросети экспертами вручную размечались динамические паттерны кардиоритмограммы, отвечающие уникальным критериям конкретного функционального состояния (рис. 2–4).

А Б

Рис. 2. Характерные для последствий COVID-19 кардиоспайки на ритмограмме больного: А – типичная для заболевания ритмограмма, Б − суперпозиция кардиоспайков

А

Б

Рис. 3. Кардиоритмограмма испытуемых с низким (А) и высоким (Б) уровнями эмоциональной дезадаптации

А Б В

Рис. 4. Характерные для эпизодов острого стресса паттерны кардиоритмограммы: А – синхронный перевод, Б – публичное выступление, В – реакция водителя автобуса на внезапный маневр другого автомобиля

Выбор модели обучения нейросети

В качестве примера стратегии решения поставленной задачи приводим алгоритм обучения нейросети автоматическому детектированию кардиоспайков, характерных для последствий COVID-19.

А Б

Рис. 5. А: Расширенная свертка с ядром = 3 и его рецептивное поле: В – вход, 1, 2, 3 – последовательные скрытые слои; Б: принципиальная блок-схема

Прежде всего, для решения задачи сегментации потока RR интервалов была выбрана сверточная сеть с растяжением (dilated convolution). Известно, что сверточные сети обладают более высокой скоростью работы и обучения перед рекуррентными сетями (RNN), которые обычно применяются в задачах детектирования и сегментации временных рядов. С другой стороны, сверточные сети требуют большего количества сверток, чтобы получить достаточное рецептивное поле, т.е. захватывать достаточно длинные временные последовательности. Для устранения этого недостатка используются свертки с растяжением, пример для трех слоев которой представлен на рис. 5, А. Необходимо подчеркнуть, что подобный принцип характерен для организации конвергентных нейронных сетей в нервной системе животных.

Растяжение для каждого последующего слоя может быть определено как d=kn-1, где n − номер сверточного слоя. Как показано на рис. 5, Б, рецептивное поле 27 и определяется как r=(k-1)i=1Lki-1+1, где L − количество слоев. Конечно, такая многослойная схема может быть эквивалентна одному сверточному слою с ядром 27, но скорость вычисления многослойного варианта выше.

А Б

Рис. 6. А: Схема детектора кардиоспайков; Б: Head Block

Известно, что скорость работы сверточного слоя можно повысить также разделением свертки на горизонтальные поканальные свертки и вертикальное межканальное смешивание. Эта схема использована для базового блока сегментатора RR интервалов. Использован Redisual Block, который является вариантом базового блока MobileNetv3, адаптированного для временных рядов. В нем сохранен основной принцип, заключающийся в расширении признакого простанства с размера (T, C) до (T, H) (Expansion Layer), поканальной свертке с пропусками, нелинейности на основе GELU проекции входа (T, H) на основе подхода Squeeze-and-Excitation [3], а также слой межканального смешивания до первоначального размера (T, C) (Compression Layer), к выходу которого подмешивается вход (Residual).

Для ускорения сходимости использован параметризованный сброс размерности (Ts, S) (Skip), который позволяет вовлекать в обучения больше глубоких слоев на самом раннем этапе.

Стоит отметить, что темпоральная размерность выхода Skip усечена слева и справа Ts=T-2P, где P − размер паддинга. Величина P определяется величиной усечения рецептивного поля крайних элементов, вызванного дополнением сверток граничными значениями для сохранения размерности, а также максимальной длительностью искомого объекта.

На рис. 6, А изображена схема детектора RR интервалов. Он состоит из F фильтров, в каждом из которых L базовых блоков, соединенных последовательно. Ответвления Skip каждого из слоев суммируются и подаются в оконечный блок сегментирования. Схема этого блока представлена на рис. 6, Б. Блок преобразует вход размерности (Ts, S) в выход (Ts, M), где M − количество классов (в работе M = 1).

Проблема обучения модели

Как уже указывалось, для обучения модели использовались размеченные экспертами записи RR интервалов, которые представляют собой последовательности задержек между соседними QRS комплексами на кардиограмме. Записи разбиваются на сегменты длины T с перекрытием 2P, отклик модели Ts соответствует центральной части сегмента, что есть T = P + Ts + P. На записях RR интервалов было предварительно размечены максимальные значения искомого спайка, которые являются целью исследования и однозначно описывают положение и размер спайка. Функция потерь была выбрана на основе широко известного FocalLoss. В качестве оптимизатора использовалась функция AdamW [13].

Эксперименты

Из собранной экспериментальной базы записей были выбраны отмеченные как спайки 2041 семпл. Во всех экспериментах использовались фиксированные параметры: длина выборки T=32, педдинг P=4, слоев в блоке L=4 и количество блоков F=2.

Выбор параметров (H, C, S) происходил на основе анализа кроссвалидационных экспериментов с разделением базы на 10 подмножеств. Метриками для оценки результата были выбраны AP (Average Precision), F1-score, F1/2-score. Эти метрики вычисляются на основе кривых точность-полнота (precision-recall) и выбраны как наиболее близко отражающие качество финальной модели, несмотря на то, что каждая из них недостаточна для

оценки качества. В качестве оценки, среди 10 кривых кроссвалидационной выборки выбиралась наихудшее значение для метрик.

Исходя из проведённых измерений, в качестве основных выбрана группа параметров модели (H, C, S) (40, 24, 72). Эксперимент показал прогнозировавшиеся изменения значений метрик в зависимости от итерации градиентного спуска. Параметр LR (Learning Rate) оптимизатора был выбран 0.01 с возможностью уменьшения в 10 раз каждые 10 эпох. Уменьшение LR происходило при выходе на плато функции потерь по валидационной выборке.

Финальная модель обучалась на разделении базы на обучающую/валидационную/тестовую в соотношении 1861/180/50 соответственно. Из проведенных экспериментов следует, что по метрике F1-score на тестовых данных точность модели не менее 0.89, а AP, F12 дают оценку в 0.94 и 0.87, соответственно.

Заключение

На примере автоматического детектирования характерных для последствий COVID-19 нарушений кардиоритма, названных нами кардиоспайками, мы постарались продемонстрировать эффективность нейросетевого подхода к разработке методов расшифровки кодов кардиоритмограммы. Ограниченность объёма публикации не позволяет детально представить аналогичные разработки по выявлению паттернов кардиоритмограммы, характерных для стресса (точность 0.88) и эмоциональной дезадаптации (0.82). Найденный нами подход позволяет надеяться на успешное применение системных нейросетевых методов для углублённого изучения механизмов формирования различных функциональных состояний и разработки способов коррекции нарушений.

Список литературы

1. Парин В.В., Баевский Р.М. Введение в медицинскую кибернетику. М.: Медицина, 1966: 220 с.
2. Polevaya S.A., Eremin E.V., Bulanov N.A., Bakhchina A.V., Kovalchuk A.V., Parin S.B. Event-related telemetry of heart rhythm for personalized remote monitoring of cognitive functions and stress under conditions of everyday activity. // Sovremennye tehnologii v medicine. 2019; 11(1): 109–115.
3. Zeveke A. V., Efes E. D., Polevaya S. A. An integrative framework of the skin receptors activation: Mechanoreceptors activity patterns versus "labeled lines" // Journal of Integrative Neuroscience 2013;12: 47–56.

4. Petukhov A.Y., Polevaya S.A. Modeling of Communicative Individual Interactions Through the Theory of Information Images// Current Psychology 2017; 36(3): 428–433.

5. Petukhov A.Y., Polevaya S.A. Dynamics of Information Images in the Mind of an Individual during Simultaneous Interpretation // Procedia Computer Science 2018; 123: 354–359.

6. Полевая С.А., Стасенко С.В., Парин С.Б., Еремин Е.В., Заречнова Н.В., Циркова М.М., Пермяков С.А. Способ регистрации постковидного состояния человека по кардиоритмограмме // Патент РФ на изобретение № 2779697 от 12.09.2022 (приоритет от 18.12.2021).

7. Григорьева В.Н., Тхостов А.Ш. Способ оценки эмоционального состояния человека // Патент РФ № 2291720 от 20.01.2007 (приоритет от 08.09.2005).

8. Полевая С.А., Парин С.Б., Шемагина О.В., Еремин Е.В., Стасенко С.В., Яхно В.Г. Способ регистрации эмоциональной дезадаптации по кардиоритмограмме // Патент РФ на изобретение № 2772185 от 18.05.2022 (приоритет от 04.12.2020).

9. Парин С.Б. Стресс, боль и опиоиды. Об эндорфинах и не только. М.: Дискурс, 2022: 208 с.

10. Parin S.B., Vetyugov V.V., Bakhchina A.V., Polevaya S.A. The role of the endogenous opioid system in the control of heart rate variability under cognitive loads of various levels // Sovremennye tehnologii v medicine 2014; 6(4): 116–126.

11. Полевая С.А., Парин С.Б., Бахчина А.В., Некрасова М.М., Шишалов И.С., Рунова Е.В., Кожевников В.В. Система определения функционального состояния группы людей // Патент РФ на полезную модель № 129680, опубл. 27.06.2013.

12. Некрасова М.М., Полевая С.А., Парин С.Б., Шишалов И.С., Бахчина А.В. Способ определения стресса // Патент РФ №2531443 от 25.08.2014.

13. Loshchilov I., Hutter F. Decoupled weight decay regularization // arXiv preprint arXiv:1711.05101. - 2017. - https://doi.org/10.48550/arXiv.1711.05101.

J. EDELEVA[1],
O.A. SMETANINA[2],
A.A. MESHCHERYAKOVA[3],
N. KUSHINA[4]
[1]Friedrich Schiller University of Jena, Ernst-Abbe-Platz 8, 07743 Jena, Germany
[2]National Research University Higher School of Economics,
Bolshaya Pecherskaya str. 25/12, 603155 Nizhny Novgorod, Russia
[3]Nizhny Novgorod State Linguistics University, Minin str. 31A,
603155 Nizhny Novgorod, Russia
[4]TU Kaiserslautern, Erwin-Schrödinger-Str. 52, 67663 Kaiserslautern. Germany
psychexpert1992@gmail.com

GERMAN-AS-A-FOREIGN-LANGUAGE (GFL) LEARNERS' RELIANCE ON 'EARLY' AND 'LATE' MORPHOLOGICAL CUES FOR STRUCTURAL ANALYSIS: THE ROLE OF COGNITIVE LOAD

We report the result of an eye-tracking study investigating cue reliance for structure building in LX learners of German at different proficiency levels. The eye movements of the participants were tracked on a three-character visual display while they were exposed to a subject or an object relative clause. After they listened to the stimulus sentence, the participants performed one of the two tasks. In one version, they had to immediately point at the intended character on the visual display. In an alternative version, they were subsequently presented with one of the three characters and had to validate or decline it as the intended/non-intended one. The latter task imposed a greater cognitive load on the participants since they had to memorize the selected character for the subsequent task. The numeric subject advantage around the relative clause offset was only evidenced in the less cognitively demanding task only. Additionally, the object relative clause condition evidenced more proportions of looks towards the embedded NP character. Thus, LX learners of German seem to emanate the processing pattern evidenced for monolingual German children and adult native speakers under a less demanding task. Our findings suggest that structural processing in morphologically rich languages is an interplay of 'early' and 'late' cues as well as the frequency of the structure itself. Simpler structures (e.g., subject relative clauses) can be computed provided there are sufficient cognitive resources while more complex structures remain challenging.

Keywords: *cognitive load, relative clauses, L2 German, sentence processing.*

1. Introduction

It is generally agreed upon that language processing is incremental. In English, the relative pronoun *that* is syncretic and subject and object relative clauses are differentiated with the help of word order. In example 1, the head NP (*the cat*) is the subject in the relative clause structure and the embedded NP (*the hedgehog*) is placed post-verbally. In example 2, the head NP is the object to the relative clause verb (*is feeding*) and the embedded NP (*the hedgehog*) occurs pre-verbally.

(1) Where is the cat that the hedgehog is feeding?

(2) Where is the cat that is feeding the hedgehog?

Numerous investigations into relative clauses repeatedly documented the subject advantage across a variety of experimental studies. In self-paced reading experiments where the participants progress through the sentence word-by-word, the relative pronoun *that* generates a local ambiguity. An increase in reaction times is observed when the parser encounters the information that disambiguates the object relative clause reading implying the parser's initial commitment to the subject interpretation. The Subject/Object Asymmetry gave rise to several computational approaches to sentence processing. Some accounts stipulate the activation of only one syntactic alternative with reliance on universal syntactic principles (Late Closure or Minimal Attachment). This initially adopted interpretation has to be abandoned when it is no longer congruent with the upcoming input. Probabilistic accounts assume that several structural alternatives may be activated simultaneously and the one with the greatest probability of occurrence will be eventually selected. Once a particular rule gets activated, a considerable processing cost towards the object relative clause is explained by the parser's surprise at the unexpected input or increased entropy (i.e., predictability metric for each upcoming part of the sentence) which makes sentence continuation less predictable.

In contrast to English where the relative clause syntax is disambiguated with the help of word order, thematic role assignment in morphologically rich languages (e.g., German) can be more reliably determined by case marking. For masculine nouns, both the relative pronoun and the embedded NP are distinctly marked for the nominative or the accusative corresponding to the subject and the object to the verb respectively (cf. examples 3 and 4).

(3) Wo ist der Kater, der gleich bestimmt den Igel füttert?

(4) Wo ist der Kater, den gleich bestimmt der Igel füttert?

At the same time, the word order remains identical and barely informative for syntactic analysis. While the subject advantage has also been documented in morphologically rich languages with relatively rigid word orders, a recent study

by Edeleva et al. [1] on Russian contests those findings. Edeleva et al. [1] contrasted simple OS- and SO-sentences where sentence-initial heteronyms (*uCHItelja* vs. *uchiteLJA*) were syncretic in reading between the nominative and the accusative or the genitive case form. In Russian, subject-initial word order (SVO) is canonical. However, the nominative case form is not necessarily more frequent than oblique case forms. Thus, the two cues give rise to a conflict regarding the structure type that they promote. Though the unambiguous case forms evidenced a strong preference for the canonical word order, the reaction times were comparable in the resolution region for the OS- and the SO-structures containing heteronyms. The comparative integration effort for either case form indicates that the parser is sensitive to distributional cues rather than purely committing itself to structural heuristics.

While respective research studies generally converge on the assumption that both the mature and the developing parser make use of distributional cues [2,3], the explanations regarding what exactly gets activated are not uniform. They range from the assumptions where specific rules are activated as a fixed component of the processing system [2] to connectionist models which acquire different syntactic rules for different languages using error-driven learning and store their frequencies. Linguistic prediction as the ability to pre-activate linguistic information before its onset appears to be the driving force of error-based learning [3] and is reliant on various cues [4]. The incremental nature of prediction, though still in dispute, is broadly acclaimed [5]. Previously mentioned computational accounts are predominantly concerned with how ‘early’ cues are exploited probabilistically to activate a particular structure type depending on its frequency. Yet, individual studies investigating child language processing of non-canonical structures stipulate that ‘late’ occurring cues might be critical for structural parsing. Thus, the way incremental prediction feeds forward and interacts with late-occurring cues remains unclear.

In a recent study of German pre-school children, Edeleva [6] suggests that children might be capable of using the accusative marking on the relative pronoun to initiate an object relative clause. However, their incremental prediction might be weaker compared to subject relative clauses due to a wide variety of factors such as their frequency, structural complexity or contextual appropriateness. The initial ‘weaker’ ORC activation will need to be verified as further more informative cues (e.g., morphological ending on the embedded NP) become available later in the sentence structure. Edeleva [6] probed this hypothesis in a visual-world eye-tracking paradigm where monolingual German children’s eye movements were tracked on a visual display while they were listening to a subject or an object relative clause. In the ORC condition, the children committed

themselves to animal character corresponding to the embedded NP from the time point when it was mentioned into the sentence offset.

In the current contribution, we seek to extend our understanding of the interaction of 'early' and 'late' cues for structural analysis and report the results of a pilot study that targets German relative clause processing in learners of German with Russian as L1. Since our participants did not necessarily learn German as their second language immediately following Russian and reported good knowledge of English (B2 and higher of CEFR), we will be calling them LX German learners. It is commonly agreed upon that L2 predictive abilities exist [7] and that they resemble those of L1 speakers [8]. Anticipation in L1 vs. L2 speakers has been studies extensively via the visual world paradigm in eye tracking across the domains of word knowledge [9], morphology [10] and syntax [11]. The studies confirm predictive processing patterns in L2 speakers. The participants favored the most probable upcoming information while listening to sentences with restrictive contexts. Yet, predictive abilities in L2 leaners might be compromised by their language proficiency and is constrained in terms of its accuracy and speed [12]. Finally, one of the debatable psychological constructs mediating linguistic prediction is cognitive load [13]. Specifically, cognitive load is assumed to explain delays in information processing with the increased task difficulty [11]. The purpose of the current study is, thus, twofold: On the one hand, it seeks to explore the ability of L2 learners at different proficiency levels for incremental prediction. On the other hand, we inquire how the use of 'early' morphological cues interacts with potential commitment to 'late' cues which become available as the sentence progresses and with the cognitive load incurred by task demands.

A visual world paradigm is employed since it allows for a time-locked and fine-grained localization of the uptake of morphological cues within the sentence structure. Further, the eye movements are largely out of conscious control. Therefore, fixation probabilities are a reliable measurement which taps into online sentence processing prior to the point in time when a particular interpretation has been reached.

2. Materials and Methods

12 visual frames (Fig. 1) depicting one animal character in the middle and two flanker characters were paired with either a subject or an object relative clause. The flanker animal characters were of the same type, but they were visually contrasted for the thematic role of the agent or the patient. The images depicted 12 actions that corresponded to 12 unique verbs. The position of the animals was balanced across the visual frames so that the animal character appeared

in the center with one verb and on the sides with a different verb. The stimuli were counter-balanced across experimental lists in a Latin-square design and pseudo-randomized with 8 filler items. To avoid the relative clause bias, the filler items contained prepositional phrases as modifiers. One experimental list contained 12 experimental items and 8 filler items.

Fig. 1. Sample Visual Display. Left-to-Right:
Agentive head NP, Embedded NP, Patient head NP

17 Russian-speaking subjects (12 females, age range 18-29 years) participated in the study on a voluntary basis. Their knowledge of German was assessed with the help of a freely available C-test. The C-test is known to have a high discriminate power regarding L2 linguistic knowledge in non-native speakers [14]. A classical version of the C-test requires the participants to supply the missing word part of every second word in four texts (approximately 70 words each). The scoring procedure was adopted from Cook et al. [15]. The responses were scored on a three-point scale: 3 points – correctly reconstructed word; 2 points – correct word base, but word form is incorrect; 1 point – citation form with the correct word base; 0 point – incorrect word base/no response. The maximum result that could be achieved on the entire C-test amounts to 432 points.

Prior to the experiment, the participants were requested to sign an informed consent form and supply their demographic data. The participants were tested individually in a special room. Experimental procedures were delivered in compliance with the ethical requirements stipulated in the Declaration of Helsinki [16].

The participants were seated at a distance of approximately 70 cm from the computer screen. Their eye movements were recorded with the help of a remote *Gazepoint* eye tracker. The sampling rate was set to 60 Hz. The experiment started with a standard 9-point calibration followed by a familiarization phase where the participants were requested to identify the animals on the screen that were subsequently used in the stimulus sentences. Each experimental trial was preceded by a drift correction. Every time drift correction failed, recalibration was performed. The participants were presented with 20 experimental sentences. After they listened to the sentence, they were subsequently asked to perform one of the two tasks: either they had to point at the character as the one intended by the sentence, or they were shown one of the characters and had to validate it as the (non-)intended one with the pre-programmed YES/NO-keys. The second task was supposed to tax the participants with a greater cognitive load during sentence processing since they had to commit the character to memory prior to its subsequent residual activation.

3. Results

Eye tracking data of 5 participants were excluded from further analysis due to poor calibration (deviation of more than 1 degree of visual angle). The data from the remaining 12 participants were submitted to statistical analysis in the R programming environment. The analysis was performed with the help of the following statistical packages: *lme4* [17], *eyetrackingR* [18], *ggplot2* [19], *buildmer* [20]. The data for the two task types: character selection and character validation – were analysed separately though the statistical procedures remained identical. Fixation probabilities towards each of the three animals on the screen were calculated separately, aggregated per condition (subject vs. object) and aligned on a time scale with the specific segments in the sentence frame that was presented auditorily (Fig. 2). Trimming for trackloss-ridden trials affected less than 10 % of the data sample.

A linear mixed effects model was constructed with fixation probabilities towards one of the characters as the dependent variable and the relative clause syntax as well as higher order polynomials and their interaction with the syntax as predictor variables. Intercepts and calculable slopes by participant and trial were included as random effects. The categorical predictor variable was centered and scaled. The *buildmer* package was used to determine the optimal linear mixed effects model based on the Akaike-criterion, with Satterthwaite approximation applied.

Fig. 2. Time-aligned fixation probabilities towards the target, the syntactic competitor and the embedded NP character in the object and the subject condition under two task versions: pointing (on the right) and validation (on the left)

For the task which additionally taxed the participants' memory capacity, fixation probabilities towards the target and away from the competitor (i.e., one of the two cats depending on the syntactic condition) evidenced a well-pronounced statistically significant subject advantage (Estimate = 4.239e-01, t=32.162, $p < .001$). By contrast, fixation probabilities towards the embedded NP (the

hedgehog) did not bear a significant effect of the relative clause syntax (Estimate = 1.464e-02, t=0.173, p = 0.886). Subsequently, post-hoc cluster-based permutation analysis using Monte-Carlo simulations with 3000 iterations was performed to determine the time windows where target fixation probabilities diverged in the two syntax conditions. The divergence shortly after the relative pronoun was approaching significance to the benefit of the subject condition (2590-4590 ms, SumStatistic = -40.71, p = 0.06). Yet, it was followed by a drop in fixations probabilities in both the subject and the object condition in the post-relative clause window (4990-5500 ms, SumStatistic = -8.40, p = 0.69).

Identical statistical procedures were applied to analyze the second task type where the participants were asked to point at the character on the screen that they assumed to be the intended one. We first computed growth curves for fixation probabilities towards the three characters on the screen. Fixation probabilities were time-aligned and augmented by condition. Overall fixation probabilities towards the target (depending on the syntactic condition) evidenced a marginal advantage towards the subject condition (Estimate = 2.122e-01, t=2.444, p=0.07). Post-hoc cluster-based permutation analysis identified three time clusters corresponding to the relative clause offset and beyond with a numeric subject advantage. However, none of them was statistically significant (3500-3700 ms: SumStatistic = -6.08, p = 0.382; 4100-4400 ms: SumStatistic = -9.28, p = 0.192; 4600-4800 ms: SumStatistic = -7.66, p=0.25). At the same time, the looks away from the competitor significantly diverged in the two conditions in the time window corresponding to the filler after the relative pronoun and the onset of the embedded NP (2900 – 3200 ms: SumStatistic = 11.988, p = 0.59)., though the overall subject advantage was barely pronounced (Estimate = -1.318e-01, t = -1.374, p = 0.241). Fixation probabilities towards the embedded NP character did not evidence a significant effect of syntax (Estimate = 1.464e-02, t = 0.173, p = 0.866). Neither could statistically significant differences be identified in specific time windows via cluster-based permutation analysis.

In summary, the structural processing pattern varied depending on the task type. While both the tasks evidenced an overall subject advantage, it was in the less cognitively demanding task type only that a clear numeric trend to the benefit of the subject condition was noted in towards the relative clause offset. Additionally, the pointing task evidenced a numeric trend in fixation probabilities towards the embedded NP character in the object condition around the relative clause offset. Those trends might reach significance if tested on a larger sample size.

4. Discussion

In the current study, we inquired LX learners at different proficiency levels make use of distributional cues for structural analysis. Previous research has repeatedly stressed the importance of the learners' predictive abilities in sentence processing. The ability to use the available cues for incremental prediction are assumed to be the driving force of error-driven learning (cf. the P-Chain Hypothesis, [3]) where the learners first have to predict the upcoming structure to drive out the prediction error in case the predicted structure does not match the input. Since prediction error creates a priming effect for a less-expected structure and, therefore, allows to update the expectation weights for particular structure types. While the P-Chain describes a plausible mechanism for the acquisition of sentence structures, the strength of a prediction might be dependent on the speaker/hearer – a factor which has not yet been sufficiently considered in computational models based on error-driven learning. In the current study, we tried to fill in this gap by looking at LX learners of German with L1 Russian. While numerous studies are directed at investigating the presence or absence of predictive abilities in L2 learners in general, specific inquiries that control for the learners' language proficiency report quantitative differences, for instance, regarding the degree of predictive lexical activation [21]. In a further study, Peters et al. [9] explored the pre-activation of potential sentence continuations that varied in probability. Anticipatory fixations towards the target varied with the learners' vocabulary size. Further, learners with lower vocabulary size made more fixations towards less expected, but locally coherent targets (cf. 'The pirate was chasing the treasure.' vs. 'The pirate was chasing the cat.'). Thus, previous findings point at greater individual variability regarding predictive abilities of language learners compared to native speakers. On the other hand, the majority of research papers focus on English as the language of investigation. Due to a great loss in inflectional morphology in the course of language change, English sentence structures are quite often locally ambiguous which contributes to the plausibility of prediction error as a learning mechanism. In morphologically-rich languages (cf. English or Russian) native speakers and monolingual children make use of morphological information as an 'early' cue for incremental prediction. Since a canonical and a non-canonical structure can generally be correctly predicted (cf. [2]), it appears somewhat counterfactual to speak about the prediction error as the choice of an incorrect structure type. While the strength of a prediction for a canonical and a non-canonical structure might be different due to differences in frequencies, it will be manifesting itself in the need to verify the less preferred structure rather than in a prediction error ([3]).

In the current study investigating LX learners of German, the participants obviously struggled to predict both the subject and the object relative clause type. A numeric subject advantage in the post-relative clause window could only be observed in the less cognitively demanding version of the task. Thus, it cannot be concluded that language learners relied solely on structural heuristics such as word order canonicity. Rather they attempted to negotiate thematic role assignment both through the 'early' and the 'late' cues. Likewise, fixation probabilities towards the embedded NP character were evidenced the pointing task type only.

Since both the structure types appeared challenging to the learners, their commitment to the 'late' cue might be evidenced via a different type of analysis where fixation probabilities towards the embedded NP are estimated against fixation probabilities towards the competitor and the target. Finally, the influence of English as their additional foreign language is not to be underestimated. Though both L1 Russian and LX German have abundant morphological cues which are more reliable for structural analysis compared to structural heuristics, the participants might be more inclined to rely on their experience processing syntactic structures of English. Along these lines, they will be making economical predictions with reliance on the 'early' cue but will pick up the 'late' cue to negotiate thematic roles closer to the sentence offset.

In summary, the data deliver further compelling evidence regarding the utility of 'early' and 'late' cues to structure building in cases where the learners' predictive abilities might be compromised through differences in second language proficiency. Specifically, we demonstrated that increased cognitive load disturbs the language processing pattern. The less taxing the task it, the closer L2 learners' performance is to the one of native speakers and monolingual children. Specifically, they showed a preference for subject relative clauses and a numeric tendency towards the embedded NP in object relative clauses. Though further research is needed to confirm those general tendencies, we conclude that cognitive load induced through the task type has a dramatic effect on sentence processing patterns in lower-proficiency second language learners. Thus, potential task-induced cognitive load should be taken into account when designing linguistic information for non-native speakers, especially at lower proficiency levels. For morphologically rich languages, task-induced cognitive load might affect the less syntactically complex structure (cf. subject relative clauses). This finding reflects that online structural processing in morphologically rich languages is generally borne out by the interaction of 'early' and 'late' distributional cues rather than by reliance on structural heuristics.

5. Conclusion

In the current study, we investigated how the processing patterns of LX learners of German are mediated by task demands. Specifically, we compared online processing of subject and object relative clauses with distinct case marking on the relative pronoun and on the embedded NP. The numeric tendency expressing the subject relative clause advantage at the relative clause offset could only be observed in the less cognitively taxing condition. Likewise, fixation probabilities towards the embedded NP character were more pronounced in the object condition when the participants did not have to memorize the head NP to subsequently validate it. Though a larger sample size is needed to statistically confirm those numeric tendencies, the processing pattern with relieved task demands resembles the one evidenced for monolingual German children. Therefore, we conclude that task demands might affect both the more and the less syntactically complex structure type alike. The processing of those structures involves the interplay of distributional cues and the degree of familiarity with the structure as a whole. As long as sufficient cognitive resources are provided, low-proficient non-native speakers can compute a more familiar canonical structure while a non-canonical one remains more challenging.

References

1. J. Edeleva, A. Chrabaszcz, V. Demareva, Resolving conflicting cues in processing of ambiguous words: The role of case, word order and animacy // Quarterly Journal of Experimental Psychology, 73 (8), 2020. P. 1173–1188.

2. D. Özge, J. Kornfilt, K. Maquate, A.C. Küntay, J. Snedeker, German-speaking children use sentence-initial case marking for predictive language processing at age four // Cognition, 221:104988, 2022.

3. G.S. Dell, F. Chang, The P-Chain: relating sentence production and its disorders to comprehension and acquisition // Philosophical Transactions of the Royal Society. Biological Sciences, 396 (1634):20120394, 2014.

4. C. Lozano-Argüelles, N. Sagarra, J.V. Casillas, Slowly but surely: Interpreting facilitates L2 morphological anticipation based on suprasegmental and segmental information // Bilingualism: Language and Cognition, 23 (4), 2020. P. 752–762.

5. G.R. Kuperberg, T.F. Jäger, What do we mean by prediction in language comprehension? // Language, Cognition and Neuroscience, 31 (1), 2016. P. 32–59.

6. J. Edeleva, Embedded NP error in German object relative clause comprehension: A case for a universal developmental pathway // Quarterly Journal of Experimental Psychology, 76 (6), 2022, 1220–1232.

7. J. Schlenter, Prediction in bilingual sentence processing: How prediction differs in a later learned language from a first one // Bilingualism: Language and Cognition, 26 (2), 2022. P. 253–267.

8. L.B. Fernandez, P.E. Engelhardt, P.E. Patarroyo, S.E. Allen, Effects of speech rate on anticipatory eye movements in the visual world paradigm: Evidence from ageing, native, and non-native language processing // Quarterly Journal of Experimental Psychology, 73 (12), 2020. P. 2348–2361.

9. R. Peters, T Grüter, A. Borovsky, Vocabulary size and native speaker self-identification influence flexibility in linguistic prediction among adult bilinguals // Applied Psycholinguistics, 39(6), 2018. P. 1439–1469.

10. V. Kuperman, A. Deutsch, Morphological and visual cues in compound word reading: Eye-tracking evidence from Hebrew // Quarterly Journal of Experimental Psychology, 73 (12), 2020. P. 2177–2187.

11. E. Chun, S. Chen, Sh. Liu, A. Chan, Influence of syntactic complexity on second language prediction // E. Kaan, Th. Grüter, Prediction in Second Language Processing and Learning, Amsterdam, John Benjamins, 2021. P. 69–90.

12. E.M. Koch, B. Bulté, A. Housen, A. Godfroid, Using verb morphology to predict subject number in L1 and L2 sentence processing: A visual-world eye-tracking experiment. // Journal of the European Second Language Association, 5(1), 2021. P. 115–132.

13. W. S. Francis, E.N. Strobach, The bilingual L2 advantage in recognition memory // Psychonomic Bulletin & Review, 20(6), 2013. P. 1296–1303.

14. V. Demareva, J. Edeleva, C. Chateau-Smith, I.Petrova, Global eye-movement measures as correlates of L2 proficiency // Journal of Language and Education, submitted.

15. S.V. Cook, N.B. Pandža, A.K. Lancaster, K. Gor, Fuzzy nonnative phonolexical representations lead to fuzzy form-to-meaning mappings. Frontiers in Psychology, 7, 2016. P. 1–17.

16. World medical association, Declaration of Helsinki: Ethical principles for medical research involving human subjects // JAMA, 310 (20), 2013. P. 2191–2194.

17. D.M. Bates, M. Maechler, Fitting linear mixed-effects models using lme4 // Journal of Statistical Software, 67 (1), 2015. P. 1-48.

18. J.W. Dink, B. Ferguson, eyetrackingR: An R library for eye-tracking data analysis, 2015.

19. H. Wickham, Ggplot2: Elegant graphics for data analysis, 2 ed., 2016, Springer International Pubishing.

20. C. C. Voeten, Package “buildmer”, 2023.

21. T. Grüter, H. Rohde, A. J. Schäfer, Coreference and discourse coherence in L2: The roles of grammatical aspect and referential form // Linguistic Approaches to Bilingualism, 7, 2017. P. 199–229.

V.N. SHATS
Independent investigator, St. Petersburg
vlnash@mail.ru

PRINCIPLE SPLITTING OF FINITE SET IN CLASSIFICATION PROBLEM

This paper deals with application of the concept feature similarity for objects of a finite set, which was proposed by the author, in the classification problem. On its basis, a method for solving the classification problem has been developed, which consists of separate stages of calculations: splitting ordered feature values into an equal number of intervals, calculating ordered pairs of object numbers and interval numbers, calculating granules containing ordered pairs of training sample objects for each class. Then, neglecting the difference in feature values within the intervals, we can calculate the frequency of granule objects for each feature using the simplest formulas of the event theory. These frequencies make it possible to calculate its frequency in each class by totality of the object's features, and then determine of the object class. Effectiveness of the method was demonstrated on 9 databases. We consider the listed stages of mapping calculation as stages of implementing the principle partitioning of a data set into a set of nested lists of ordered pairs. This principle was developed when solving the problem of estimating closeness classes and clusters of a set calculated on its basis. The results of its solution for 10 combined databases indicate the promise of applying the principle.

Keywords: *Ordered Feature Value, Information Granules, Holism.*

Introduction

Similarity concept is one of the fundamental ones in machine learning, since that is what allows you to compare sets that describe training sample objects (TRS) in order to recognize objects of different classes and apply this knowledge when breaking test sample objects (TS) into classes [1]. Usually, similarity measure of two objects is assessment of their proximity by the distance between them in a metric space. In [2, 3], the concept features similarity for objects of a finite set is proposed, according to which the feature values for objects of the same class are close if sufficiently small difference between these values. The concept opens up new possibilities for solving classification problems and generates new computing technologies in the classification problem based on set splitting.

Let us introduce several definitions. The values totality of feature k for a sample of length l will be called the set of feature values $\{x_{jk} | j \in \{1, \dots, l\}\}$, whose elements can have equal values. The values of this feature will be called ordered if they are renamed and receive numbers $(j) = (1), (2), \dots, (l)$ such that $x_{(1)k} \leq x_{(2)k}, \cdots, \leq x_{(l)k}$. Let the OFV denote one or more ordered values of the same feature. Further, the ordered feature value (OFV) denotes one or more such values. Object set $\{s\} = \{1, \cdots, l\}$ are considered to be ordered if pairwise distances between objects in the metric space such that

$$d_{(1)(2)} \leq d_{(2)(3)}, \cdots, \leq d_{(l-1)(l)}.$$

In the author's papers, OFV diagrams were proposed, which, likewise to the method of invariant grids [4], visualize all the information for each feature contained in the TRS. Diagrams for several databases showed that the OFV distributions are different for objects of any class. This conclusion led to the new concept and the development of the object number list method (ONLM) to solve the classification problem. Let's consider its features, since they reveal the specifics application of the principle splitting of set.

The computational procedure directs to approximation of features distributions of combined sample (CS) objects. For the CS, each OFV is divided into the same number of intervals (it serves as a parameter). Then the assumption is introduced that within each interval of the feature, difference in the feature values for all objects falling within the interval can be neglected. Now we can approximate structure of the given data by passing from the data matrix to its mapping to the list set of the CS object numbers for each feature and the interval number (hereinafter, the index) of its values. Then, in each such list, we select the TRS objects of the same class and make lists of their object numbers, named information granules [5, 6].

In accordance with the concept feature similarity and the assumption made, it is assumed that the granule as a whole and the object features that form it have the same statistical characteristics. The granule frequency is calculated as a complex event depending on the class length and index of granule objects for certain feature. Then the object frequency in each class is calculated by the simplest formula of probability theory for the complete group of independent events of granules appearance for features containing the corresponding object number.

We were unable to find in the modern literature a similar approach, where the analysis of TRS is based on the existing concept of closeness and therefore aims to determine the object characteristics of various classes as a whole [7–9]. Note that the use of the ONLM leads to a radical change in the structure of the representation of set and simplifying its algorithm. Then the main elements of the

calculations are one-dimensional quantities, which are the OFV of separate objects, and not multidimensional ones, which are the objects as a whole.

Moreover, the ONLM operates mainly not with the OFV of certain objects, but with their characteristics - the numbers of objects and indexes of their feature values. Only at the last stage, the results of calculations for the object as a whole are generalized as for certain totality of its feature values. Therefore, the role of the nearest neighbor here is “performed” not by one object, but by all objects from the corresponding interval. By that increases the reliability of feature frequency estimates as class indicators. It can be considered that the ONLM uses a new method for estimating nonparametric regression [10], which combines the well-known methods of nearest neighbors and granulation.

The new method has common roots with the remaining unfinished general theory of pattern recognition [11]. According to the theory, information at different hierarchical levels is divided into many disjoint blocks information with selection of the simplest standard blocks at the lower level. Here, information granules are analogues of such blocks.

There are also other "interruptions" with existing methods. The composition and frequency of the granules depend on the parameter mentioned above. Thus, for each of its values, we consider a different approximation of the TSR, and in fact, the ONLM uses the properties of the sample ensemble, as is customary in the bagging method [12]. In addition, in the mentioned works of the author, it was shown that, according to [13, 14], the ONLM is a bio-inspired and robust method.

It should be noted that the simplicity, robustness and efficiency of the developed algorithm were confirmed experimentally on 9 databases [15].

The effect of knowledge systematization based on the philosophical concept of holism was manifested in the ONLM [16]. From the holism view point, the ONLM comes down to the multiple division of the whole into parts. So the value set of each feature is divided into equal intervals, for each feature lists of objects falling into the intervals are formed, and these lists are divided into classes, forming information granules - lists of objects of the same class, feature and index. According to the new concept, under the above assumption, objects of the same class are "similar". In fact, this means that the granule objects have similar properties and possibly belong to the same class. The above transformations of the given data structure are considered in the article as stages of implementing the principle partitioning of set, on the basis of which the given set is transformed into a set of nested lists of object numbers.

This paper also considers the ratio problem of objects number that form classes of a given set and the corresponding clusters calculated according to the principle partitioning of set. The principle was developed in its solution (see below). The corresponding calculations performed on its basis for 10 databases showed a significant relationship between classes and clusters.

Closeness of classes and clusters corresponding the principle

Consider the following problem of estimating the closeness of classes and clusters calculated according to the principle splitting of set. Let

$$Q = \{(\boldsymbol{x}_s, i_s) | s \in \{1, \dots, M\}\}$$

be the set of images of objects $\boldsymbol{x}_s = (x_{s1}, \dots, x_{sN})^T$ that belong to the classes $i \in \{1, \dots, C\}$ and have $k \in \{1, \dots, N\}$ features. Let A be a set of real objects, features are quantitative or categorical. It is required to find a function $f: A \to W$ implements the similarity concept and associates the classes of the set A with clusters W, as well as the closeness level ψ of classes and clusters. Its value is equal to the total number of identical numbers of real objects of classes and corresponding objects of clusters, divided by the length of the set Q. Here we mean that the set A is not a surjective mapping of the set Q, since it is impossible to establish a one-to-one correspondence between real objects and their images, however, these sets have a single numbering of objects.

Application of the similarity concept is usually based on the assumption that the object proximity in a certain metric space may indicate their belonging to the same class. We change the idea of this assumption as follows. Consider a sequence of ordered distances between object numbers $(s) = 1, \dots, M$. We divide the segment $(0, M)$ into a sequence of segments $l_1, l_2, \dots, l_C$, each of which is equal to the length of the corresponding class $i \in \{1, \dots, C\}$. Numbers of the set objects $\{s\} \leftarrow \{(s)\}$ belonging to segments l_i will be called clusters of class i for the corresponding metric. Analogous approach is applied to the ordered numbers of objects of each feature.

For each set Q, calculations were performed for 5 variants of metrics that determine the distance $\varrho(\boldsymbol{x}, \boldsymbol{y})$ between objects x and y in the feature space [17]:

$$\varrho(\boldsymbol{x}, \boldsymbol{y}) = \left(\sum_{s=1}^{n} |x_s - y_s|\right)^{1/p}, \ \varrho(\boldsymbol{x}, \boldsymbol{y}) = \max_{s=1,\dots,n} |x_s - y_s|.$$

The first of the formulas for $p = 2$ is valid for the Euclidean metric and for $p = 1, 1.33, 1.67$ for the Minkowski metric, the second formula is valid for the Chebyshev metric. Let $j = 1, 2, \dots, 5$ be the numbers of variants of a given set for ordered objects. Obviously, we have N options for ordered features, and the total number of options for a subset of clusters is $5 + N$. The value ψ is calculated for

each variant j of the cluster subset. Thus, in this problem, we study several options for implementing the principle.

Table 1

Database characteristics

Database	M	N	C	Feature type
Abalone	4177	8	29	mix.
Adult	42121	14	2	mix.
Breast Cancer	699	9	2	int.
Car evaluation	1728	6	4	mix.
Glass	214	9	6	quant.
Haberman's Survival	306	3	2	int.
Iris	150	4	3	quant.
Letter Image Recognition	20000	16	26	int.
Spect	267	2	22	int.
Wine	178	4	3	quant.

According to these formulas, we first calculate the maximum distance of feature object s for each feature to all other objects in the set Q and determine its maximum value. By ordering the set of these values, we determine the ordered number (s) for any feature of the object s.

Calculations were performed for 10 databases, the characteristics of which are shown in Table 1, the results are shown in Table 2. From the table follows the value of ψ exceeded 0.9, 0.7 and 05 for 2, 4 and 6 out of 10 database options, respectively, the maximum value of ψ = 0.961, only for one option ψ ~ 0.

We see that in many cases classes and clusters consist of the same objects, and according to the principle splitting of set. This result is unexpected, but to a certain extent corresponds to the ideas about the role of order in nature [18]. From the standpoint of cognitive psychology [19], the fact of the relationship between the compositions of classes and clusters, apparently, is due to the fact that the range of possible values of the features of object images is also important for an expert. It can be expected that the will find application in solving practical problems of dividing a set of data into classes.

Table 2

Closeness levels of classes and clusters for databases

Datebase	**Closeness level**
Abalone	0.325 0.344 0.343 0.339 0.344 0.319 0.319 0.318 0.328 0.325 0.322 0.326 0.318
Adult	0.638 0.634 0.656 0.634 0.674 0.767 0.666 0.645 0.525 0.74 0.531 0.611 0.509 0.639 0.7 0.68 0.671 0.729 0.65
Breast Cancer	0.458 0.467 0.464 0.464 0.534 0.49 0.464 0.455 0.49 0.473 0.485 0.458 0.499 0.531
Car evaluation	0.548 0.539 0.521 0.538 0.553 0.707 0.582 0.554 0.571 0.547 0.599
Glass	0.36 0.393 0.43 0.411 0.21 0.178 0.379 0.164 0.453 0.308 0.262 0.159 0.435 0.21
Haberman's Survival	0.595 0.608 0.601 0.608 0.562 0.961 0.601 0.627
Iris	0.12 0.127 0.133 0.153 0.067 0.727 0.207 0.947 0.947
Letter Image Recognition	0.037 0.039 0.039 0.04 0.04 0.04 0.039 0.038 0.038 0.039 0.039 0.038 0.037 0.038 0.036 0.039 0.039 0.039 0.039 0.04 0.038
Spect	0.543 0.543 0.543 0.543 0.506 0.483 0.491 0.513 0.521 0.543 0.521 0.506 0.483 0.543 0.483 0.491 0.483 0.491
Wine	0.253 0.247 0.23 0.236 0.382 0.14 0.376 0.281 0.528 0.185 0.219 0.27 0.5 0.236 0.264 0.185 0.225 0.135

Method algorithm of object number list

The ONLM algorithm is designed to solve the classification problem for a sample represented by a set $\{(\boldsymbol{x}_s, y_s)|s \in \{1, \dots, M\}$ of objects $\boldsymbol{x}_s = (x_{s1}, \dots, x_{sN})^T$, which belong to the classes $y_s \in \{1, \dots, C\}$ and have features $k \in \{1, \dots, N\}$. Features are quantitative or categorical. It is required to find a solution for objects of the TRS and check it on the rest of the sample – the test sample TS.

Note that the features of the TRS are not order statistics, since the values of features $\boldsymbol{x}^k = (x_1^k, \cdots, x_M^k)^T$ have different distribution functions. Therefore, the apparatus of order statistics [20] cannot be applied here.

The solution was obtained on basis of the feature similarity concept and is reduced to computing a mapping of a given set onto a set of nested lists of object numbers, which implements the principle splitting of set. We use the following procedure for any feature k.

Let us order the feature values and then divide the entire range of its values into n equal intervals $h_k = (x_k^{max} - x_k^{min})/(n-1)$, where n is parameter, x_k^{min} and x_k^{max} are the minimum and maximum values of the feature, respectively. Let $1,2,\dots,n$ be the interval boundary numbers. Roughly speaking, the difference in feature values can be neglected over the length of the interval. Then we can measure the values of feature x_k in integers $m \in \{1,\dots,n\}$, called indices $m = W({}^{x_k}/_{h_k})$, where $W(\cdot)$ is integer part of the number.

As a result, for each n we get a mapping of the given set onto the set of ordered pairs $\{\{(k,m)\}|k \in \{1,\dots,N\}, m \in \{1,\dots,n\}\}$. Any pair is a list of object numbers with close feature values. If the list is not empty, then it contains objects that have feature values $x_k \in [m * h_k, (m+1) * h_k)$. Only features of objects that have $x_k = m * h_k$ will be accurately described using indices. The feature values of the remaining objects will be presented with an error not exceeding h_k.

Now we splitting the subsets of the set of ordered pairs related to the TSR objects by classes into subsets $\{\omega_{km}^i\} = \{\{(k,m)\}|i \in \{1,\dots,C\}\}$, which we will call information granules (k,m) of class i. The granule is list of object numbers of certain class the TSR, which for any object of the list are considered as nearest neighbors by the value of the corresponding feature.

Now we can find a set of comparative granule frequencies $\{f_{km}^i\}$ for different the TSR classes. Its value is taken equal to the comparative frequency of the nearest neighbor of object s by feature k in class i:

$$f_{km}^i = \frac{l_{km}^i}{L_i l_{km}}, \tag{1}$$

where l_{km}^i and l_{km} are the number of granules ω_{km}^i and the total number of pairs (k,m) respectively, L_i is the length of class i.

Let $p_i(x_{sk})$ be the probability that feature k of object s in class i has index m. Since $p_i(s) = p(s \in \omega_i | x_{sk} = m)$, then $p_i(x_{sk}) = f_{k,m}^i / M$. The event of feature appearance of an object$s$ (number s) of any class consists of a complete group of independent events $x_{s1},\dots,x_{sN}$. For objects of class i according to the total probability formula we obtain

$$p_i(s) = \frac{1}{MN}\sum_{k=1}^{N} f_{k,m}^{i}\,. \qquad (1)$$

Then the calculated class of the object s is equal to

$$I(s) = \arg max_{1\le i\le C}\, p_i(s). \qquad (2)$$

Formulas (1)–(3) are valid for the TRS and TS objects since they belong to a single sample. They give a solution for each value n for objects of the TRS and TS corresponding to the stages of training and classification. The solution quality will be evaluated by the total error rates $\nu = \nu(n)$ for the TRS and TS that occur in the case of $I(s) \neq y_s$.

The problem is reduced to determining the value range of parameter n, within which the solution will be recognized as acceptable in a particular problem in terms of error rates for training and for classification, calculated in accordance with the cross-validation procedure. As calculations have shown, we can restrict ourselves to calculating the values of ν on the set As calculations have shown, we can restrict ourselves to calculating the values of ν on the set $n \in \{25, \dots, 50\}$.

Conclusions

The paper is devoted to application of the concept feature similarity for objects of a finite set and the method developed on its basis for solving the classification problem. It has a simple, robust and bio-inspired algorithm tested on 9 databases. The results obtained made it possible to formulate the principle splitting of set in the classification problem and to propose a new technology for its solution. It provides for performing the main amount of calculations not on the elements of a given data set, but on the elements of a set of nested lists of object numbers.

It is shown that in the classification problem the considered principle plays the role of a mechanism for the implementation of the philosophical concept of holism.

Here we are also dealing with the problem of number ratio of the same object numbers that form the classes of a given set and the corresponding clusters calculated according to the principle of splitting this set. In the problem, several variants of applying of the considered principle are studied. Calculations for 10 databases have shown that for some variants the closeness level. The result obtained indicates the prospects of applying the principle.

References

1 Luger G. Artificial intelligence: structures and strategies for complex problem solving. Addison-Wesley Springer, New York. 2016.

2 Shats V. Properties of the ordered feature values as a classifier basis. Cybernetics and physics. 2022. 1(11). P. 25–29.

3 Shats V. Approximation of the data structure in the classification problem. In: Proceeding XXIV International Conference Neuroinformatics, MEPhi, Moskow. 2022. P. 473–481.

4 Gorban A., Karlin I. Invariant Manifolds for Physical and Chemical Kinetics. Springer, Berlin. 2005. DOI: 10.1007/b98103

5 Yao J., Vasiliacos, V., Pedrycz, W. Granular computing: Perspective and challenges. IEEE Trans. Cibernetics. 2013. 43 (6). P. 1977–1989. DOI: 10.1109/TSMCC.2012.2236648.

6 Li J., Mei C., Xu W., Quian Y. Concept learning via granular computing: A cognitive viewpoint. Information sciences, 298. 2015. P. 447–467. DOI: 10.1016/j.ins.2014.12.010.

7 Bishop C. Pattern Recognition and Machine Learning. Springer, Berlin. 2006.

8 Hastie T., Tibshirani R., Friedman J. The Elements of Statistical Learning: Data Mining, Inference, and Prediction. 2nd Edition, Springer, Berlin. 2009.

9 Murphy K. Machine Learning. A Probabilistic Perspective. MIT Press, Cambridge, Massachusetts, London. 2012.

10 Tsybakov A. Pattern Recognition and Machine Learning. Springer, Upper Saddle River. 2006.

11 Grenander U. Lectures on pattern theory. V. 1: Pattern Synthesis.. Springer-Verlag, New York-Heidelberg-Berlin. 1976.

12 Breiman L. Bagging predictors. Machine Learning, 24. 1996. P. 123–140.

13 Shats V. The classification of objects based on a model of perception. In: Kryzhanovsky B. et al. (eds.) Advances in Neural Computation, Machine Learning, and Cognitive Research, Studies in Computational Intelligence, Springer, Moscow. 2018. P. 125–131.

14 Jaynes E. Probability Theory: The Logic of Science. Cambridge University Press, Berlin Heidelberg. 2003.

15 Asuncion, A., Newman D.J. UCI Machine Learning Repository. Irvine. University of California, Irvine. 2007.

16 Calabrese M. A., Amato A., Lecce V. D., Piuri V. Hierarchical-granularity holonic modelling. Journal of Ambient Intelligence and Humanized Computing.2012. 1(3), pp. 199–209. DOI: 10.1007/s12652-010-0013-3.

17 Kolmogorov A. N., Fomin S. V. Elements of the theory of functions and functional analysis. Vol. 1. 1957. Metric and normed spaces. Graylock Press Rochester, New York.

18 Prigogine I., Stengers I. Order Out of Chaos: Man's New Dialogue with Nature. Flamingo Edition, London. 1984.

19 Solso R. Cognitive psychology. 6-th ed. Allyn and Bacon. Boston. London. Toronto. 2006.

20 David H., Nagaraja H. Order Statistics. 3 rd ed. Wiley-Interscience, New Jersey. 2003.

Секция

Прикладные нейросетевые системы

А.В. БУХ, Е.В. РЫБАЛОВА, И.А. ШЕПЕЛЕВ, Т.Е. ВАДИВАСОВА
Саратовский национальный исследовательский государственный университет имени Н. Г. Чернышевского
buh.andrey@yandex.ru

КЛАССИФИКАЦИЯ МУЗЫКАЛЬНЫХ ИНТЕРВАЛОВ В ЦЕПОЧКЕ ОСЦИЛЛЯТОРОВ ФИТЦХЬЮ-НАГУМО*

Работа посвящена исследованию релевантных биологии нейронных сетей, которые называются спайковыми нейронными сетями, и направлена на классификацию музыкальных интервалов. Каждому интервалу отвечает своя цепочка нейронов с уникальной топологией, что позволяет с помощью спайковой нейронной сети классифицировать элементарные аудио-сигналы.

Ключевые слова: *спайковые нейронные сети, осциллятор ФитцХью-Нагумо, топология связей, музыкальные интервалы.*

Введение

Биологические нейронные сети представляют интерес, поскольку ответственны за когнитивную деятельность высших животных и человека. Работа посвящена исследованию релевантных биологии нейронных сетей, которые называются спайковыми нейронными сетями, и направлена на классификацию музыкальных интервалов. Каждый интервал в музыке представляет собой созвучие из двух нот. При этом интервалы могут отстраиваться от разных звуков, но интервалы с одним и тем же отношением частот являются одинаковыми. Мы предлагаем использовать специальную топологию связей в цепочке из 12 осцилляторов ФитцХью-Нагумо в возбудимом состоянии для обеспечения реакции нейронов на выбранный музыкальный интервал. В результате подбора специальной топологии и силы

*Исследование выполнено при финансовой поддержке РНФ в рамках научного проекта № 23-12-00103.

связей цепочка осцилляторов ФитцХью-Нагумо демонстрирует спайковую активность только при подаче на сеть одного из музыкальных интервалов. На другие интервалы с такой же амплитудой сигнала цепочка не реагирует и остается в состоянии покоя. Каждому интервалу отвечает своя цепочка нейронов с уникальной топологией, что позволяет с помощью спайковой нейронной сети классифицировать элементарные аудио-сигналы.

Модель и результаты

Численные исследования модели цепочки связанных осцилляторов ФитцХью-Нагумо [1, 2] были выполнены при наличии внешнего воздействия со стороны контуров с трением:

$$\varepsilon\dot{x}_i = x_i - \frac{x_i^3}{3} - y_i + ku_i + \frac{\sigma}{2}\sum_j \left(x_j - x_i\right),$$
$$\dot{y}_i = x_i + a,$$
$$\dot{u}_i = v_i,$$
$$\dot{v}_i = -\gamma v_i - \omega_i^2 u_i + A_1 \sin\omega_1 t + A_2 \sin\omega_2 t,$$

где переменные x, y – активатор и ингибитор в модели ФитцХью-Нагумо, а переменные u, v определяют динамику контура, на который подается внешний сигнал, представляющий собой сумму двух гармонических сигналов. Параметр временного масштаба $\varepsilon = 0.01$, параметр связи с контуром $k = 1$, параметр возбуждения генератора $a = 1.03$, параметр трения контура $\gamma = 0.02$, параметр частоты каждого контура ω_i настраивается на выбранные тоны, а параметры внешнего воздействия $A_1 = 0.001, A_2 = 0.001$. Параметры частоты внешнего воздействия ω_1 и ω_2, а также параметр силы связи между осцилляторами σ изменяются.

На рис. 1 представлена диаграмма, на которой отражена работа нейронных сетей с разной топологией в случае воздействия на них одного и того же музыкального интервала, отложенного от различных базовых тонов, при различной силе связи в цепочке осцилляторов ФитцХью-Нагумо. По горизонтальной оси отложен номер эксперимента, в котором выбирается топология из 11 заготовленных вариантов и подаваемый музыкальный интервал (изменяются как интервал, так и его левая граница по частоте). Эксперимент проведен для одного и того же музыкального интервала «прима», отложенного от разной базовой частоты, результаты сгруппированы по фиксированным интервалам: например, первые 11 случаев отвечают разной топологии связей, но одному музыкальному интервалу – «прима», отложенному от ноты «до» первой октавы. По вертикальной оси отложена сила связи в цепочке

нейронов. Красными точками на рисунке отмечены случаи, когда выбрана топология, для которой ожидается генерация спайков, но сеть нейронов осталась в состоянии покоя (false negative); синими точками отмечены случаи (интенсивностью синего отражена нормированная на единицу частота генерации спайков), которые соответствуют нежелательной генерации спайков (false positive); а зеленым цветом – случаи ожидаемого поведения сети. В результате можно выделить диапазон значений сил связей (ограничен черными линиями на рисунке), в котором цепочки нейронов демонстрирует нужное поведение и происходит точная классификация музыкальных интервалов на «прима» и отличающиеся от него.

Рис. 1. Диаграмма режимов в цепочке осцилляторов ФитцХью-Нагумо в случае воздействия на цепочки с разной топологией различных музыкальных интервалов (ось абсцисс) при различной силе связи (ось ординат). Красными точками на рисунке отмечены случаи, когда выбрана топология, для которой ожидается генерация спайков, но сеть нейронов осталась в состоянии покоя (false negative); синими точками отмечены случаи (интенсивностью синего отражена нормированная на единицу частота генерации спайков), которые соответствуют нежелательной генерации спайков (false positive); а зеленым цветом – случаи ожидаемого поведения сети (classified)

Выводы

В результате численного исследования были определены параметры связи в кольце осцилляторов ФитцХью-Нагумо, которые обеспечивают возможность классификации двухчастотных сигналов по отношению частот друг ко другу.

Численные эксперименты были проведены для идеального случая, в отсутствии шума при одинаковой амплитуде составляющих интервал сигналов и при отсутствии дополнительных гармоник. В дальнейшем планируется исследование влияния шума, дополнительных гармоник и различий в амплитудах сигналов, составляющих интервалы.

Список литературы

1. FitzHugh R. Impulses and physiological states in theoretical models of nerve membrane // Biophysical journal. – 1961. – Т. 1. – No. 6. – С. 445–466.
2. Nagumo J., Arimoto S., Yoshizawa S. An active pulse transmission line simulating nerve axon // Proceedings of the IRE. – 1962. – Т. 50. – No. 10. – С. 2061–2070.

Н.П. ШЛАПАК
Обнинский институт атомной энергетики НИЯУ МИФИ
shlapaknp@oiate.ru

ИССЛЕДОВАНИЕ ВОЗМОЖНОСТИ ИСПОЛЬЗОВАНИЯ ПРЕДОБУЧЕННОГО АВТОЭНКОДЕРА ДЛЯ АНАЛИЗА С ПОМОЩЬЮ МЕТОДА ГЛАВНЫХ КОМПОНЕНТ

Рассматривается возможность использования нейросетевой модели для выделения главных компонент из массива данных на примере распределения поля энерговыделения в активной зоне реактора ВВЭР-1000. Проведено сравнение с детерминистическими алгоритмами, предложен, разработан и протестирован алгоритм подготовки модели.

Ключевые слова: *реактор ВВЭР-1000, метод главных компонент, сингулярное разложение, разложение Карунена-Лоэва, автоэнкодер.*

Введение

При эксплуатации сложных технологических объектов часто возникает задача определения состояния оборудования по множественным сигналам, генерируемым этим оборудованием. К таким задачам относится анализ со-

стояния активной зоны (далее – АЗ) ядерного реактора. Для контроля протекающей цепной ядерной реакцией (и, как следствие, контроля всей реакторной установки) критически необходимо иметь достоверное представление о числе нейтронов, способных вызывать деление ядер урана.

В реакторе ВВЭР-1000 эту функцию выполняет система внутриреакторного контроля. Она включает в себя аппаратуру контроля нейтронного потока (далее – АКНП), состоящую из 64 каналов нейтронных измерений (далее – КНИ), каждый из которых состоит из 7 детекторов прямого заряда (далее – ДПЗ) и расположен внутри тепловыделяющей сборки (далее – ТВС). КНИ и ДПЗ равномерно распределены по объёму АЗ, вследствие чего становится возможным восстановить поле энерговыделения и получить необходимую для эксплуатации информацию о нейтронном потоке.

Таким образом, состояние АЗ описывается матрицей размерности 64x7 или 448 значениями. Такой объём информации слишком велик для непосредственного анализа человеком с приемлемой скоростью. Эта проблема может быть нивелирована с помощью применения метода главных компонент [1].

Метод главных компонент – это статистический метод обработки данных, заключающийся в переходе из одного пространства признаков в пространство признаков меньшей размерности. Трудность представляет минимизация потери информации при таком переходе. Однако даже сама оценка потери информации может оказаться затруднённой в силу специфики задачи.

Одним из наиболее простых способов выделения главных компонент является использование ковариационной матрицы [2]. Таким образом, в новом пространстве максимизируется дисперсия набора данных относительно каждой оси (компоненты). Пример приведён на рис. 1.

Рис. 1. Пример использования алгоритма выбора на основе минимальной дисперсии

Однако, такой алгоритм будет неприменим для задачи, данные в которой будут распределены как на рис. 1 (справа) в случае, если необходимо сохранить свойство кластеризуемости.

Ранее было предложено использовать разложение Карунена-Лоэва [1, 3], использующее вместо ковариационной матрицы корреляционную. В современных математических пакетах различных языков программирования используется сингулярное разложение матрицы [4]. Все эти методы предполагают использование громоздких математических преобразований. Альтернативным методом выделения главных компонент может стать использование автоэнкодера.

Постановка задачи

Для обучения нейросети и сравнения алгоритмов были использованы данные, полученные со второго блока Калининской АЭС. Данные представляют собой непрерывный временной ряд из показаний каждого ДПЗ при выборочном поодиночном вводе и выводе 18 регулирующих стержней.

Влияние каждого поглощающего стержня на распределение поля энерговыделения и, как следствие, показания ДПЗ однозначно и строго определено: чем глубже погружён стержень, тем больше нейтронов он поглощает и, соответственно, тем меньше будут значения показаний ДПЗ в соседних ТВС. Таким образом, становится возможным по восстановленному полю энерговыделения определить факт ввода стержня и его расположение.

Алгоритм такого определения уже был разработан [5]. Он предполагает использование свёрточной нейросети, обученной на исчерпывающем объёме обучающих данных. Поскольку, в рассматриваемой задаче число анализируемых параметров значительно меньше, то было решено не задействовать свёрточную часть предложенной авторами модели. Таким образом, для классификации будет использоваться нейросетевая модель, состоящая из четырёх полносвязных слоёв. На вход подаются значения 10 главных компонент (число выбрано произвольно), а на выходе ожидается получить 18 значений, обозначающих вероятность того, что данное состояние относится к тому или иному классу (введён соответствующий стержень).

Точность (долю правильно определённых состояний) такого определения мы будем использовать в качестве основной метрики, отображающей практическую применимость сравниваемых методов преобразования.

В качестве классификатора будет использована нейросеть, разработанная ранее [5]. Для обучения и тестирования данные каждый раз будут произвольным образом делиться в соотношении 70 % обучающих образцов, 10 % валидационных и 20 % – тестовых.

После выделения главных компонент интерес представляет оценка количества информации, передаваемое каждой из них, а значит, и потеря информации при снижении размерности. Этот показатель предлагается определять следующим образом:

$$I_k = \frac{D_k}{\sum D} * 100\%, \tag{1}$$

где I_k – доля информации, передаваемая k-й компонентой, а D_k и $\sum D$ – дисперсия по k-й компоненте и суммарная дисперсия по всем компонентам соответственно.

Математические основы применяемых методов

Положим, что каждый объект x – состояние активной зоны реактора ВВЭР-1000 – может быть представлен в $n = 448$-мерном пространстве признаков, где каждый признак – показание одного из ДПЗ. В таком случае между различными признаками будет существовать сильная функциональная зависимость, а значит, такая система координат не ортогональна.

Рассмотрим выборку из m состояний. Её можно отобразить в виде матрицы X размерностью $m \times n$:

$$X = \begin{pmatrix} f_1(x_1) & \cdots & f_n(x_1) \\ \vdots & \ddots & \vdots \\ f_1(x_m) & \cdots & f_n(x_m) \end{pmatrix} = \begin{pmatrix} x_1 \\ \vdots \\ x_m \end{pmatrix} \tag{2}$$

Тогда в новом k-мерном ($k \leq n \leq rank(X)$ пространстве признаков этой выборке будет соответствовать матрица

$$C = \begin{pmatrix} g_1(x_1) & \cdots & g_n(x_1) \\ \vdots & \ddots & \vdots \\ g_1(x_m) & \cdots & g_n(x_m) \end{pmatrix} = \begin{pmatrix} y_1 \\ \vdots \\ y_m \end{pmatrix} \tag{3}$$

Будем искать такое линейное преобразование

$$x = yU^T, \tag{4}$$

которое бы позволило однозначно преобразовывать данные из одного пространства в другое с минимальной потерей информации.

Погрешность, обуславливающую потерю информации при восстановлении исходных данных $\tilde{x}$, можно выразить в виде

$$\Delta^2(C, U) = \sum_{i=1}^{m} \| \tilde{x}_i - x_i \|^2 = \| CU^T - X \|^2 \tag{5}$$

Минимальность этой погрешности обеспечивается, когда столбцы матрицы U являются собственными векторами матрицы $\Phi = X^T X$, соответствующие k наибольшим собственным значениям этой матрицы. Эти векторы называют главными компонентами.

Если положить $k = n$ и $C = VD$, где матрица D – диагональная, а V – ортогональная, то можно перейти к сингулярному разложению матрицы X:

$$X = VDU^T \tag{6}$$

При $k < n$ представление $X \approx CU^T$ становится приближённым. Потери информации могут быть оценены с помощью (1). Преобразование U (разложение Карунена-Лоэва) является ортогональным, т.к. корреляции между новыми признаками отсутствуют. Это позволяет использовать одну и ту же матрицу для преобразования как в прямом направлении, так и в обратном. Т.е.

$$C = XU; \quad X = CU^T \tag{7}$$

Для наглядности было произвольно выбрано число выделяемых главных компонент $k = 10$.

Обоснование применимости автоэнкодера

Автоэнкодер (или автокодировщик) представляет собой нейросетевую модель, состоящую из двух нейросетей: кодера и декодера. Схематически эта структура изображена на рис. 2.

Рис. 2. Схематическое изображение автоэнкодера

Принцип работы такой нейросети заключается в максимально точном восстановлении входных данных на выходе. Чтобы данные не проходили через всю модель без изменений, кодер от декодера отделяют слоем, содержащим значительно меньшее число нейронов, чем входной (или выходной). Этот слой называют скрытым состоянием.

Точность восстановления в большой степени зависит от числа нейронов в скрытом слое и выбора функции потерь. Использование в её качестве среднего квадрата отклонения в виде

$$\delta = \frac{1}{m}\sum_{i=1}^{m}(\tilde{x}_i - x_i)^2 \qquad (8)$$

отождествляет задачу обучения автоэнкодера с задачей минимизации (5), рассмотренной с детерминистической точки зрения в предыдущей главе.

Предлагаемая методика предполагает, что модель будет заранее обучена на большом количестве данных, полученных в ходе работы блока, а затем использована для автоматической работы в режиме «он-лайн». Это позволит ускорить обработку данных, сохранив при этом её качество. Также нейросетевая модель может дообучаться в ходе эксплуатации, повышая при этом точность своей работы, чувствительность к незначительным изменениям и т.п.

Результаты

Дисперсии по каждой из 10 выделяемых компонент приведены в табл. 1.

Таблица 1

Дисперсии по компонентам, выделенным различными способами

Номер компоненты	Сингулярное разложение	Разложение Карунена-Лоэва	Автоэнкодер
1	18,072908	17,287096	0,113739
2	1,073487	1,055622	0,009082
3	0,818226	0,768220	0,006815
4	0,686729	0,654620	0,004471
5	0,259502	0,265923	0,001637
6	0,227972	0,218191	0,001509
7	0,175259	0,190719	0,001061
8	0,107483	0,102802	0,000905
9	0,103944	0,096994	0,000649
10	0,088396	0,100304	0,000603

Такое существенное различие между результатами, полученными с помощью автоэнкодера и матричных преобразований объясняется тем, что для лучшего обучения нейросети абсолютные значения компонент требуется нормировать. На матричные разложения такого ограничения не накладывается.

Тем не менее, если оценить информативность каждой компоненты согласно (1), станет заметно, что различия не так значительны (табл. 2 и рис. 3).

Таблица 2

Относительные дисперсии по компонентам, выделенным различными способами

Номер компоненты	Сингулярное разложение	Разложение Карунена-Лоэва	Автоэнкодер
1	0,836170	0,833495	0,809695
2	0,049666	0,050897	0,064651
3	0,037856	0,037040	0,048515
4	0,031773	0,031562	0,031827
5	0,012006	0,012821	0,011657
6	0,010547	0,010520	0,010744

Продолжение табл. 2

Номер компоненты	Сингулярное разложение	Разложение Карунена-Лоэва	Автоэнкодер
7	0,008109	0,009195	0,007557
8	0,004973	0,004957	0,006442
9	0,004809	0,004677	0,004621
10	0,004090	0,004836	0,004292

Наиболее существенным недостатком применения такого автоэнкодера для выделения главных компонент является невозможность контролировать, какому из нейронов скрытого состояния будет соответствовать определённая компонента. Для его устранения необходимо усложнять либо структуру сети, либо функцию потерь, что представляет собой тему для дальнейших исследований.

Для оценки качества классификации состояний по главным компонентам, выделенным нейросетью было разработано две методики:

1. Модель-классификатор обучается на всех трёх выборках (матричные преобразования и заранее сгенерированные автоэнкодером значения), а затем оценивается её точность по каждой отдельно.

2. Автоэнкодер дополняется вторым выходом и подключённой к нему моделью-классификатором. В таком случае обучение обеих моделей происходит одновременно.

Рис. 3. Информативность главных компонент, выделенных различными способами

Первый подход предоставляет более строгое сравнение, однако второй более приближен к реальным условиям эксплуатации алгоритма, так как подразумевает более быстрое обучение и допускает дообучение в режиме «он-лайн»

Результаты приведены в табл. 3.

Таблица 3

Сравнение точности классификации

	Точность классификации, %
Сингулярное разложение	71,32
Разложение Карунена-Лоэва	71,42
Автоэнкодер	41,50
Автоэнкодер с классификатором	63,24

Сниженная точность автоэнкодера объясняется упомянутой ранее невозможностью заранее определить, какая компонента какому нейрону соответствует, а также недостатками строения модели. Подобранные макропараметры могут не быть оптимальными.

Заключение

Исследование возможности использования нейросети вместо матричных преобразований представляет интерес для более детального изучения, однако, на основании проведённых исследований можно заключить, что такая замена будет уместна в задачах, в которых необходима быстрая качественная оценка и допускается снижение её точности.

Невозможность определить принадлежность конкретного значения к определённой компоненте также накладывает ограничения на применимость такого алгоритма. Однако, при анализе не одного отдельного состояния, а сразу нескольких, установить такое соответствие становится возможным. Для этого необходимо вычислить дисперсии по каждой выделяемой компоненте и отсортировать их по убыванию.

Весомым преимуществом использования нейросети является отсутствие необходимости строить матрицу преобразования и, как следствие, возможность обучать модель на данных с одной реакторной установки и использовать на другой, проведя дообучение на небольшой выборке, полученной либо предварительно, либо в ходе эксплуатации в фоновом режиме.

Список литературы

1. Алыев Р.Р., Лескин С.Т. Метод анализа работоспособности измерительной системы и программного обеспечения внутриреакторного контроля ВВЭР-1000 // Известия вузов. Ядерная энергетика. 2008. № 3. С.4–12.
2. Shlens J. A Tutorial on Principal Component Analysis. New-York. 2009.
3. Гонсалес Р., Ту Дж. Принципы распознавания образов. М.: Мир. 1978.
4. Minka T. P. Automatic choice of dimensionality for PCA // M.I.T. Media Laboratory Perceptual Computing Section Technical Report No. 514. Cambridge. 2000.
5. Иваницкая Е.С., Лескин С.Т., Шлапак Н.П. Анализ состояния активной зоны реактора ВВЭР-1000 по показаниям СВРК с использованием нейросетевых алгоритмов // Сборник докладов международной научной конференции «Техногенные системы и экологический риск». 2022. С.31–32.

И.А. СОЛОВЬЕВ, В.В. КЛИНЬШОВ
Институт прикладной физики РАН, Нижний Новгород
solocool46@gmail.com

ПОРОГИ УСТОЙЧИВОСТИ АТТРАКТОРОВ СЕТИ ХОПФИЛДА[1]

Цель работы заключается в изучении аттракторов сети Хопфилда и бассейнов их притяжения в зависимости от размера сети и числа запомненных образов. Показано, что зависимость среднего порога устойчивости полезных аттракторов от числа запомненных образов может быть немонотонной, за счет чего устойчивость сети может возрастать при запоминании новых образов. Анализ порогов устойчивости позволил оценить максимальное количество образов, которые может хранить сеть без фатальных ошибок в их распознавании.

Ключевые слова: *динамические сети, коллективная динамика, ассоциативная память.*

Введение

Сеть Хопфилда [1] является классической моделью ассоциативной памяти. Функция памяти в этой сети реализуется за счет ее коллективной динамики, которая обеспечивает восстановление сохраненной в ней информации по предоставленному фрагменту. Для этого связи в сети выбираются по определенному правилу. При этом в фазовом пространстве этой системы происходит формирование аттракторов, соответствующих сохраняем данным.

Предложенная более сорока лет назад модель Хопфилда по сей день привлекает внимание исследователей в области нейронауки. Рассматривались варианты сети как в классическом дискретном, так и в непрерывном исполнении [2]. Были предложены реализации сети Хопфилда в виде физических систем, например оптических [3] или в виде цепей фазовой автоподстройки частоты [4]. Были рассмотрены возможности решения с помощью сети Хопфилда задач оптимизации [5] и линейного программирования [6]. Большое внимание при исследовании сетей Хопфилда уделялось иссле-

[1] Работа выполнена при поддержке Российского Научного Фонда, грант № 19-72-10114.

дованию емкости памяти, то есть максимального количества данных, которое система способна запомнить без существенного ухудшения производительности [7,8]. Недавно появились также так называемые новые сети Хопфилда (modern Hopfield networks, [9]) или сети плотной ассоциативной памяти (dense associative memories, [10]), в которых более сильная нелинейность в нейронах позволяет сохранять в сети существенно больший объем информации. Емкость памяти такой системы можно рассматривать как максимальное количество кодирующих информацию аттракторов, которые могут быть созданы в фазовом пространстве одновременно. Помимо таких «полезных» аттракторов, соответствующих запоминаемой сетью информации, при настройке матрицы связей возникают и другие, так называемые «паразитные» аттракторы, не соответствующие никаким сохраненным данным. Так как в процессе работы сеть, двигаясь в фазовом пространстве, приходит к какому-то конечному устойчивому состоянию, важной характеристикой аттракторов обоих типов является их бассейн притяжения − множество всех начальных состояний сети, из которых она эволюционирует к данному аттрактору. В контексте ассоциативной памяти бассейн притяжения аттрактора − это совокупность различных начальных данных, которые сеть распознает как соответствующий образ из ее памяти.

Настоящая работа посвящена исследованию аттракторов сети Хопфилда. Исследованы зависимости их бассейнов притяжения от размера сети и количества запомненных образов. Бассейны притяжения описывались численной мерой – порогом устойчивости, равным минимальному расстоянию от аттрактора до границы его бассейна [11]. Для паразитных аттракторов была также исследована зависимость их количества от размера сети и числа запомненных образов.

Модель сети

Рассматривается дискретный вариант сети Хопфилда. Каждый нейрон описывается переменной состояния V_i, которая принимает значение 0 или 1. Вектор из таких переменных $\boldsymbol{V}$ будем также называть «образом». Сеть работает в дискретном времени. Если T_{ij} − коэффициенты связи между нейронами (элементы матрицы связей $\boldsymbol{T}$), то состояние элементов изменяется во времени по следующему закону: если сумма всех $T_{ij}V_j$ больше 0, V_i = 1, если меньше V_i = 0. При этом в [1] показано, что, если задать матрицу связей на основе некоторых S образов, которые мы хотим запомнить, они будут аттракторами сети Хопфилда. В дальнейшем такие аттракторы будут называться «полезными».

Паразитные аттракторы

В сети могут возникать так называемые «паразитные» аттракторы, которые не соответствуют никакой запомненной информации. Их наличие оказывает существенное влияние на работу сети как системы памяти, поэтому важно исследовать вопрос об их наличии и их количестве в системе. Важно также понять, являются ли такие аттракторы искаженными версиями полезных или принципиально новыми состояниями.

Рис. 1. Среднее количество паразитных аттракторов в сети Хопфилда в зависимости от ее размера (*a*) и от числа запомненных образов (*b*)

Для исследования количества и расположения паразитных аттракторов было проведено численное моделирование в зависимости от размера сети N и количества запомненных образов S. Для каждого набора параметров рассматривалось 360 различных реализаций сети, в каждой из которых запоминались S случайных образов. Для каждой реализации сети выбиралось 100 начальных условий и моделировалась динамика сети до ее прихода к аттрактору, в результате чего составлялся список уникальных паразитных аттракторов. Важно отметить, что для любого аттрактора сети инвертированный образ также является аттрактором, что легко показать на основе правила (1). Поэтому аттракторы, являющиеся инвертированными запомненными образами, не считались паразитными. Также два паразитных аттрактора, являющиеся инвертированными версиями друг друга, считались за один.

Рис. 2. Среднее расстояние от паразитных аттракторов до ближайшего полезного и ближайшего паразитного аттрактора в зависимости от размера сети (*a*) и от числа запомненных образов (*b*)

На рис. 1 и 2 приведены результаты исследования, усредненные по всем реализациям сети. На рис. 1, *a* представлена зависимость количества уникальных паразитных аттракторов от размера сети N, а на рис. 1, *b* – от числа сохраненных образов S. Зависимость числа паразитных аттракторов от размера сети является монотонно возрастающей и носит насыщающийся характер. Гораздо более интересна зависимость числа паразитных аттракторов от количества запомненных образов S. Эта зависимость является немонотонной с максимумом при $S = 7–8$, причем это значение практически не меняется при варьировании N в широких пределах от 20 до 600. На рис. 2 приведены данные о среднем расстоянии от паразитного аттрактора до ближайшего полезного аттрактора, а также до ближайшего другого паразитного аттрактора. При этом расстояние между двумя образами рассчитывалось как расстояние Хэмминга, то есть определялось число несовпадающих элементов, а затем нормировалось на N.

Интересно что зависимость от числа запомненных образов существенно различна для расстояния до ближайшего паразитного и ближайшего полезного аттрактора. В первом случае она является монотонно убывающей, а во втором демонстрирует минимум при $S = 4$, причем это значение практически одинаково для всех N в пределах от 20 и до 600.

Бассейны притяжения аттракторов

Важной характеристикой аттрактора является бассейн притяжения − множество начальных состояний, из которых система приходит в данный аттрактор. Применительно к ассоциативной памяти для полезных аттракторов это множество образов, которые система успешно распознает, а для паразитных − множество образов, распознавание которых приводит к сбою в работе системы. В таком многомерном фазовом пространстве, как у сети Хопфилда, описание бассейнов притяжения − очень нетривиальная задача, однако были предложены несколько численных мер для характеристики бассейнов. Например, бассейновая устойчивость [12] характеризует объем бассейна в фазовом пространстве. Порог устойчивости [11] представляет собой кратчайшее расстояние от аттрактора до границы его бассейна притяжения. Для системы ассоциативной памяти порог устойчивости полезных аттракторов представляется наиболее информативной характеристикой, так как он задает максимальную степень искажения образа, которая гарантированно не повлияет на успех его распознавания сетью. При этом возмущение, соответствующее порогу устойчивости, является минимальным искажением образа, которое приводит к сбою работы системы. Нахождение такого возмущения позволяет определить «слабое место» системы, уязвимое для возможных атак [13].

Для определения порога устойчивости сети Хопфилда был использован вариант градиентного спуска, предложенного в [11], модифицированный для дискретных систем. Алгоритм стартует со случайного образа U, находящегося вне бассейна притяжения интересующего нас аттрактора V, и пытается приблизиться к аттрактору, делая шаги в его направлении. Это происходит следующим образом: из множества элементов образа U, отличающихся от соответствующих элементов вектора V, случайным образом выбирается один элемент, и его значение инвертируется, что приводит к уменьшению расстояния между U и V. В случае попадания образа U в бассейн притяжения аттрактора V сделанный шаг отвергается, в противоположном случае он принимается. Описанные шаги повторяются до тех пор, пока не возникает ситуация, в которой не удается сделать никакого следующего шага. В этом случае образ U находится на границе бассейна притяжения аттрактора V, причем достигнут локальный минимум расстояния между аттрактором и границей его бассейна притяжения. Стартуя с различных начальных образов U, алгоритм находит множество локальных минимумов, и минимальный из них принимается в качестве оценки порога устойчивости.

Исследование порогов устойчивости

С помощью алгоритма спуска было проведено исследование бассейнов притяжения аттракторов обоих типов в зависимости от размера сети и количества запомненных образов. Для каждой пары и рассматривались 120 различных реализаций сети, запоминаемые образы генерировались случайно. В каждой реализации сначала находились паразитные аттракторы, а затем вычислялись пороги устойчивости полезных и найденных паразитных аттракторов. Полученные результаты были усреднены по реализациям сети, а также по всем соответствующим аттракторам.

Результаты исследования представлены на рис. 3, на которых показана зависимость нормированных на размер сети порогов устойчивости от размера сети и числа запомненных образов. Зависимость его от размера сети насыщается при больших N как для полезных, так и для паразитных аттракторов. Таким образом, аттракторы в больших сетях $N >> S$ характеризуются достаточно сильной устойчивостью. Видно, что для вывода системы из их бассейна притяжения необходимо изменить состояние 15–25 % элементов.

Рис. 3. Зависимость среднего порога устойчивости от размера сети N при различном числе запомненных образов S, указанном на рисунке, для полезных аттракторов (*a*) и паразитных аттракторов (*b*)

Интересна зависимость порогов устойчивости от числа запомненных системой образов (рис. 4). Для полезных аттракторов зависимость различна для малых и больших N. В то время как для небольших сетей порог устойчивости монотонно убывает с ростом количества запомненных образов,

для больших размеров зависимость носит немонотонный характер. Сначала порог устойчивости убывает и достигает локального минимума, затем возрастает, однако при дальнейшем запоминании новой информации снова спадает.

Рис. 4. Зависимость среднего порога устойчивости от числа запомненных образов S при различном размере сети N, указанном на рисунке, для полезных аттракторов (a) и паразитных аттракторов (b)

Наличие этого возрастающего участка, казалось бы, противоречит интуиции, так как при добавлении в систему новых аттракторов средний размер их бассейнов притяжения уменьшается, и логично предположить, что пороги устойчивости также будут уменьшаться. Однако оказывается, что наиболее глубокие «впадины» становятся мельче. Это приводит к увеличению порога устойчивости бассейна. Данное наблюдение приводит к не интуитивному способу увеличения устойчивости системы к внешним атакам: в некоторых случаях для этого можно добавить в систему новые запомненные образы, что приведет к увеличению порогов устойчивости. Однако, эта «аномальность» присутствует только при небольшом по сравнению с размером числе образов. Любое дальнейшее увеличение S, всегда приводит к уменьшению порога устойчивости. Для паразитных аттракторов порог устойчивости также уменьшается с ростом S, как показано на рис. 4, b. При больших S порог устойчивости паразитных аттракторов уменьшается медленнее, чем у полезных аттракторов, и при определенном числе запомненных образов их значения становятся равными.

Число образов, при котором достигается такое равенство, является важной характеристикой системы, определяющей предельное количество образов, которые система может запомнить и корректно распознать.

Определим его как S^*. Тогда из графиков 4 a, b имеем $S^* = 0{,}1N$. Такое критическое значение достаточно близко к оценке максимального количества образов, которые можно запомнить, в оригинальной работе Хопфилда [1]. Полученные оценки порогов устойчивости аттракторов обоих типов позволяют получить новую, независимую оценку критического количества запомненных образов, которая хорошо согласуется с «традиционной».

Заключение

Проведено исследование аттракторов и их бассейнов притяжения в сети Хопфилда. Показано, что при сохранении в системе более двух образов в фазовом пространстве в дополнение к соответствующим им полезным аттракторам появляются и паразитные аттракторы, не соответствующие и не близкие ни к каким из запомненных образов. Число паразитных аттракторов демонстрирует насыщающуюся зависимость от размера сети и немонотонную зависимость с выраженным максимумом от числа запомненных образов. Паразитные аттракторы располагаются достаточно далеко от полезных аттракторов и друг от друга.

Для изучения бассейнов притяжения был использован метод на основе порога устойчивости, предложенный в работе [11]. Данный метод позволяет найти минимальные по амплитуде возмущения аттрактора, приводящие к выходу из его бассейна притяжения. В контексте ассоциативной памяти, реализуемой в сети Хопфилда, эта характеристика соответствует минимальному искажению образа, приводящему к его неправильному распознаванию. Эта характеристика важна с точки зрения определения уязвимых мест для атак сети. Для вычисления самих порогов устойчивости была предложена модификация алгоритма градиентного спуска для дискретных систем. С помочью этого алгоритма было проведено детальное исследование получаемых бассейнов в зависимости от параметров системы – количества запомненных образов и размера сети.

Были изучены зависимости порогов устойчивости как полезных, так и паразитных аттракторов сети от ее параметров. Наиболее интересной является зависимость среднего порога устойчивости от количества запомненных образов при больших размерах сети N. Данная зависимость демонстрирует выраженный минимум, откуда следует неожиданная возможность увеличения устойчивости сети к внешним атакам путем добавления в ее

память дополнительных образов. На основе исследования предложен новый критерий определения максимального числа образов, которое способна хранить система без существенного ухудшения качества их распознавания: это такое число образов, при котором порог устойчивости полезных аттракторов становится равным (в среднем) порогу устойчивости паразитных аттракторов. Показано, что таким способом определенное критическое число образов близко к классической оценке емкости системы $0{,}1N$, а критический порог близок к единице. Таким образом, метод порогов устойчивости позволил получить новую важную информацию о свойствах сети Хопфилда.

Список литературы

1. Hopfield JJ. Neural networks and physical systems with emergent collective computational abilities. Proc. Natl. Acad. Sci. U. S. A. 1982;79(8):2554–2558. DOI: 10.1073/pnas.79.8.2554.

2. Hopfield JJ. Neurons with graded response have collective computational properties like those of two-state neurons. Proc. Natl. Acad. Sci. U. S. A. 1984;81(10):3088–3092. DOI: 10.1073/pnas. 81.10.3088.

3. Farhat NH, Psaltis D, Prata A, Paek E. Optical implementation of the Hopfield model. Applied Optics. 1985;24(10):1469–1475. DOI: 10.1364/AO.24.001469.

4. Hoppensteadt FC, Izhikevich EM. Pattern recognition via synchronization in phase-locked loop neural networks. IEEE Transactions on Neural Networks. 2000;11(3):734–738. DOI: 10.1109/ 72.846744.

5. Joya G, Atencia MA, Sandoval F. Hopfield neural networks for optimization: study of the different dynamics. Neurocomputing. 2002;43(1–4):219–237. DOI: 10.1016/S0925-2312(01)00337-X.

6. Wen UP, Lan KM, Shih HS. A review of Hopfield neural networks for solving mathematical programming problems. European Journal of Operational Research. 2009;198(3):675–687. DOI: 10.1016/j.ejor.2008.11.002.

7. McEliece R, Posner E, Rodemich E, Venkatesh S. The capacity of the Hopfield associative memory. IEEE Transactions on Information Theory. 1987;33(4):461–482. DOI: 10.1109/TIT.1987.1057328.

8. Storkey A. Increasing the capacity of a hopfield network without sacrificing functionality. In: Gerstner W, Germond A, Hasler M, Nicoud JD. editors. Artificial Neural Networks – ICANN'97. ICANN 1997. Vol. 1327 of Lecture Notes in Computer Science. Berlin, Heidelberg: Springer; 1997. P. 451–456. DOI: 10.1007/BFb0020196.

9. Krotov D, Hopfield JJ. Dense associative memory for pattern recognition. In: NIPS'16: Proceedings of the 30th International Conference on Neural Information Processing Systems. 5–10 December 2016, Barcelona, Spain. New York: Curran Associates Inc.; 2016. P. 1180–1188. DOI: 10.5555/ 3157096.3157228.

10. Ramsauer H, Schäfl B, Lehner J, Seidl P, Widrich M, Adler T, Gruber L, Holzleitner M, Pavlović M, Sandve GK, Greiff V, Kreil D, Kopp M, Klambauer G, Brandstetter J,

Hochreiter S. Hopfield networks is all you need [Electronic resource]. arXiv:2008.02217. arXiv Preprint; 2020. 94 p. Available from: https://arxiv.org/abs/2008.02217.

11. Klinshov VV, Nekorkin VI, Kurths J. Stability threshold approach for complex dynamical systems. New Journal of Physics. 2016; 18(1):013004. DOI: 10.1088/1367-2630/18/1/013004.

12. Menck PJ, Heitzig J, Marwan N, Kurths J. How basin stability complements the linear-stability paradigm. Nature Physics. 2013; 9(2):89–92. DOI: 10.1038/nphys2516.

13. Chakraborty A, Alam M, Dey V, Chattopadhyay A, Mukhopadhyay D. Adversarial attacks and defences: A survey [Electronic resource]. arXiv:1810.00069. arXiv Preprint; 2018. 31 p. Available from: https://arxiv.org/abs/1810.00069.

Е.А. ШАМАРИНА, А.И. ГУСЕВА, В.С. КИРЕЕВ

Национальный исследовательский ядерный университет «МИФИ», Москва

aiguseva@mephi.ru

СЕНТИМЕНТ-АНАЛИЗ НА ОСНОВЕ НЕЙРОСЕТЕЙ-ТРАНСФОРМЕРОВ

В статье рассматриваются результаты сравнительного анализа применения двух моделей нейросети BERT-Base и BERT-Large для определения тональности текста на наборе данных в виде новостных публикаций агентства BBC за 2019–2022, содержащие 16169 статей на английском языке. Выявлено, что обе модели обладают высокой точностью классификации текстов (0,88), а значения функции потерь для них малы и составляют значения в диапазоне 0,19–0,21.

Ключевые слова: *анализ тональности, классификация настроений текста, модель обучения, предварительная обработка данных, модель BERT, Pytorch.*

Введение

С быстрым ростом информации, накапливающейся на интернет-порталах, в электронных СМИ, социальных сетях и блогах, анализ тональности или настроений становится все более актуальным направлением исследований в области обработки естественного языка, которое широко используется как в академических, так и в промышленных кругах.

Анализ настроений (сентимент-анализ) – это процесс сбора и анализа мнений, мыслей и впечатлений людей относительно различных тем, продуктов, сюжетов и услуг. Мнения людей могут быть полезны корпорациям,

правительствам и частным лицам для сбора информации и принятия решений, опирающихся на общественное мнение. Например, результаты сентимент-анализа могут оказать значительное воздействие на программы лояльности, которые формируются при реализации сложных мегапроектов, в частности при строительстве атомных электростанций. Анализ настроений (тональности) выявляет и извлекает субъективную информацию из текста с помощью технологий обработки естественного языка и интеллектуального анализа текста.

В данной статье обсуждаются возможности использования нейросети-трансформера BERT для анализа тональности текстов.

Состояние проблемы

Как правило, анализ тональности формулируется как процедура идентификации, распознавания и / или категоризации эмоций, настроений или мнений пользователей в отношении любого объекта – мнения могут быть положительными, отрицательными или нейтральными [1]. Постановка задачи может быть различной: когда настроение определяется как полярность, то рассматривается задача классификации. Когда для выражения эмоций используются оценки настроений, лежащие в определенном диапазоне (например, колесо эмоций), задача рассматривается как задача регрессии [2, 3].

В настоящее время в анализе тональности текстов выделяются такие виды задач классификации, как классификация тональности, классификация субъективности, анализ тональности на основе характеристик, сравнительный анализ тональности, поиск мнений, выявление фальшивых мнений, определение полезных мнений [4].

В интеллектуальных методах анализа тональности выделяют подходы, основанные на лексике, машинное и глубокое обучение, гибридные подходы.

Лексические подходы, применяемые для анализа настроений, основываются на словаре либо на корпусе слов [5]. В первом случае классификация настроений выполняется с использованием словаря терминов. В настоящее время существует ряд библиотек – тезаурусов, в которых уже классифицированы слова с учётом их эмоциональной окраски (SentiWordNet, WordNet-Affect, SenticNet, LIWC, The Harvard inquirer). Анализ настроений на основе корпуса основывается не на предопределенном словаре, а на использовании таких методов статистического анализа, как k-ближайших соседей (k-NN) [6], условном случайном поле (CRF) [8], скрытых марковских моделях (HMM) [9], и т.д.

Методы, основанные на машинном обучении, можно разделить на две группы: традиционные модели и модели глубокого обучения [10]. Традиционные модели относятся к классическим методам машинного обучения, таким как наивный байесовский классификатор [11], классификатор максимальной энтропии [12] или машины опорных векторов (SVM) [13]. Входные данные для этих алгоритмов включают лексические признаки, признаки, основанные на лексике настроений, части речи или прилагательные и наречия. Точность классификации этих систем зависит от того, какие функции выбраны.

Модели глубокого обучения могут обеспечить лучшие результаты по сравнению с традиционными моделями, так как используют технологии обработки естественного языка NLP. С помощью NLP мнения, содержащиеся в онлайн-комментариях, публикациях в социальных сетях, блогах и другой информацией, обрабатываются и представляются в виде шаблонов и структур, которые могут использоваться программным обеспечением для их понимания и реализации. Анализ настроений можно рассматривать как подмножество NLP, которое помогает пользователям принимать решения, основанные на мнении. Различные задачи NLP, такие как токенизация, стемминг, лемматизация, обнаружение отрицания, создание n-граммы и извлечение признаков, помогают в анализе тональности [14]. Предварительная обработка на основе NLP помогает улучшить производительность классификатора полярности за счет анализа лексики настроений [15]. В результате NLP облегчает понимание текста, точно фиксирует полярность текста и, в конечном счете, способствует улучшению анализа настроений [16].

Для анализа настроений можно использовать различные виды моделей глубокого обучения, такие, как CNN, DNN и RNN. Такие подходы решают проблемы классификации на уровне документа, предложения или аспекта. Глубокое обучение адаптирует многослойный подход к скрытым слоям нейронной сети. Глубокая нейронная сеть – это нейронная сеть с более чем двумя слоями, некоторые из которых являются скрытыми слоями. Глубокие нейронные сети используют сложное математическое моделирование для обработки данных самыми разными способами [17]. В традиционных методах машинного обучения признаки определяются и извлекаются вручную, либо с использованием методов выбора признаков. В моделях глубокого обучения признаки изучаются и извлекаются автоматически, что обеспечивает более высокую точность и производительность.

Сверточная нейронная сеть CNN представляет собой особый тип нейронной сети с прямой связью, архитектура которой состоит из уровней свертки, объединения или подвыборки для предоставления входных данных, и полностью связанный уровень [18]. Слои свертки фильтруют свои

входные данные для извлечения объектов; выходные данные нескольких фильтров могут быть объединены. Объединение слоев (субдискретизация) уменьшают разрешение объектов, чтобы уменьшить количество параметров и объем вычислений. Это может повысить надежность CNN и позволяет избежать переобучения. Полностью связанные слои выполняют задачи классификации.

Рекуррентные нейронные сети RNN представляют собой класс нейронных сетей, связи между нейронами которых образуют направленный цикл, который создает петли обратной связи внутри сети [19]. Основной функцией RNN является обработка последовательной информации на основе внутренней памяти, организованной в виде направленных циклов. В отличие от традиционных нейронных сетей, RNN может запоминать предыдущее вычисление информации и может повторно использовать ее, применяя к следующему элементу в последовательности входных данных.

Особым типом RNN является сети с длинной кратковременной памятью (LSTM), которые способны использовать длинную память в качестве входных данных для функций активации в скрытом слое [20].

Гибридные подходы [21] сочетают подходы, основанные на лексике и машинном обучении. Настроенные словари обычно играют ключевую роль в большинстве этих стратегий.

Глубокое обучение на основе нейросетевых трансформеров появились относительно недавно. В частности, модель BERT (Bidirectional Encoder Representations from Transformers, 2017 г.) предобучается на больших объемах текстовых данных и формирует векторные представления слов, которые зависят от контекста слова. Такие контекстуализированные векторные представления могут быть далее использованы в различных нейросетевых архитектурах для решения большого количества разнообразных задач. Использование архитектуры типа BERT привело к росту качества решения задач автоматической обработки текстов, включая задачи анализа тональности [22–23].

Таким образом, исследования тональности текстов с помощью различных нейросетевых архитектур является актуальной задачей. В данной работе для исследования тональности публикаций в электронных СМИ были использованы нейросети-трансформеры BERT.

Постановка задачи исследования

Провести вычислительный эксперимент по оценке тональности набора текстовых публикаций с помощью двух архитектур BERT-трансформеров (BERT-Base и BERT-Large) и сравнить полученные результаты.

Методология исследования и данные

В качестве используемых для сентимент-анализа нейросетей были использованы модели BERT-base и BERT-large из фреймворка Pytorch Bert:

- BERT-base содержит 12 слоев, 768 скрытых узлов, 12 голов внимания, 110 миллионов параметров;
- BERT-large содержит 24 слоя, 1024 скрытых узла, 16 голов внимания, 340 миллионов параметров.

Рис. 1. Этапы проведенного исследования

Само исследование проводилось в 5 этапов (рис. 1).

Этап 1. С помощью обученной модели из nltk Vader проведен анализ тональности текстов.

Этап 2. Использованы предварительно обученные модели BERT-base/ BERT-large для преобразования текста в векторное представление (эмбеддинги).

Этап 3. Из векторизованных текстов была сформирована сбалансированная выборка, содержащая равное количество текстов негативной и положительной тональности (1000 текстов в каждой категории).

Этап 4. Был создан классификатор на основе сети глубокого обучения, состоящий из скрытых 4 слоев, состоящих соответственно, из 768, 256, 128, 64 нейронов. В качестве функции активации использована линейная функция ReLu. Далее, выборка, полученная на этапе 3, была разделена на 70 и 30 % рандомизированным образом, где большая часть данных использована для обучения.

Этап 5. Обученный классификатор был применен на тестовой выборке, для каждой из моделей векторизации, после было проведено сравнение качества полученной тональности для BERT-base/ BERT-large.

Набором данных в данном случае являлись новостные публикации агентства BBC за 2019–2022, содержащие 16169 статей на английском языке. Статьи предварительно были размечены в виде таблицы со столбцами: название статьи, время публикации, уникальный идентификатор, ссылка, описание.

Полученные результаты

На первом этапе исследования проведен анализ тональности набора 16169 текстов с помощью обученной модели из nltk Vader. Полученные результаты: 0,38 – отрицательная тональность, 0,36 –положительная, 0,26 – нейтральная.

На втором и третьем этапах использовались BERT-base и BERT-large.

Для оценки качества модели и сравнительного анализа были выбраны две стандартные характеристики:

- функция потерь loss, т.е. среднеквадратичная ошибка между предсказанными значениями тональности и фактическими значениями тональности в процессе обучения модели;
- точность precision, т.е. абсолютная ошибка между предсказанными значениями тональности и фактическими значениями тональности в процессе обучения модели. Точность показывает долю правильных предсказаний.

На рис. 2 представлены результаты обучения модели BERT-base по 200 эпохам. По оси абсцисс указаны эпохи, по оси ординат – значение функций ошибок. По рисунку видно, что на первых 70–75 эпохах значения функций изменяются, начиная с 100-ой эпохи значения стабилизируются. Минимальные потери в процессе обучения составили 0,006, а максимальная точность достигла 0,993.

На рис. 3 представлены результаты обучения модели BERT- large по 200 эпохам. По оси абсцисс указаны эпохи, по оси ординат – значение функций ошибок. Минимальные потери в процессе обучения составили 0,011, а максимальная точность достигла 0,989. Также как для предыдущей модели, значения функций стабилизируются. Но в данном случае стабилизация наступает начиная с 110 эпохи.

Рис. 2. График функции потерь (loss) и точности (precision)
в процессе обучения по 200 эпохам: модель BERT-base

Рис. 3. График функции потерь (loss) и точности (precision)
в процессе обучения по 200 эпохам: модель BERT-large

В табл. 1 представлены результаты сравнительного анализа моделей по тестовой выборке. Объем ее составил 600 статей.

Таблица 1

Сравнительный анализ моделей BERT

Модель	Значение функции потерь	Точность	Количество текстов положительной тональности	Количество текстов отрицательной тональности
BERT-base	0.214	0.88	300	295
BERT-large	0.190	0.88	310	290

Как видно из таблицы, точность анализа тональности текстов у обоих моделей практически одинакова, различие состоит в значении функции потерь – у модели BERT-base оно выше на 13 %.

Следует отметить, что полученные значения показывают очень хороший результат сентимент-анализа. Например, в работе [23] точность модели Tatyana-ruBert составила 0,771, модели ruBert-base – 0,742 и модели ruBert-tiny 0,71 соответственно. Одной из причин такого расхождения результатов является сложность языка, так как в данном исследовании были использованы тексты на английском языке, а в работе [23] – на русском.

Выводы

Проведен вычислительный эксперимент по оценке тональности набора текстовых публикаций с помощью двух архитектур BERT-трансформеров: BERT-base и BERT-large. Полученные результаты показывают, что точность анализа тональности текстов у обоих моделей практически одинакова, различие состоят в значении функции потерь – у модели BERT-base оно выше на 13 %.

Программа дальнейших исследований будет включать в себя исследование применимости моделей BERT-base/ BERT-large на наборах данных, собранных в электронных СМИ за 2019–2022 гг. в странах Белоруссии, Венгрии и Турции, и посвященных строительству российских объектов атомной генерации.

Список литературы

1. Mehta P, Pandya S. A review on sentiment analysis methodologies, practices and applications // Int J Sci Technol Res. 2020. V. 9(2). P. 601–609.

2. Cortis K., Freitas A., Daudert T., Huerlimann M., Zarrouk M., Handschuh S., Davis B. Semeval-2017 task 5: Fine-grained sentiment analysis on financial microblogs and

news // 11th International workshop on semantic evaluations (SemEval-2017): Proceedings of the workshop. Stroudsburg. PA. USA. Association for Computational Linguistics (ACL). 2017. P. 519–535.

3. Vakali A., Chatzakou D., Koutsonikola V., Andreadis G. Social data sentiment analysis in smart environments-extending dual polarities for crowd pulse capturing // International conference on data management technologies and applications. V. 2. SCITEPRESS. 2013. P.175–182.

4. Гусева А.И., Киреев В.С., Бочкарёв П.В. Исследование цифровой тени проектов строительства российских АЭС за рубежом с помощью методов интеллектуального анализа текстов // Приборы и системы. Управление, контроль, диагностика. 2023. № 6. С. 50–57.

5. Wankhade M., Rao A.C.S., Kulkarni C. A survey on sentiment analysis methods, applications, and challenges // Artif Intell Rev 55. 2022. P. 5731–5780. DOI: https://doi.org/10.1007/s10462-022-10144-1.

6. Salas-Zárate M.P., Medina-Moreira J., Lagos-Ortiz K., Luna-Aveiga H., Rodriguez-Garcia M.A., Valencia-García R.J.C. Sentiment analysis on tweets about diabetes: An aspect-level approach // Computational and mathematical methods in medicine. 2017. V. 5. P. 1–9. DOI:10.1155/2017/5140631.

7. Huq M.R.; Ali A.; Rahman A. Sentiment analysis on Twitter data using KNN and SVM. IJACSA // Int. J. Adv. Comput. Sci. Appl. 2017. V. 8. P. 19–25.

8. Pinto D., McCallum A., Wei X., Croft W.B. Table extraction using conditional random fields // Proceedings of the 26th Annual International ACM SIGIR Conference on Research and Development in Information Retrieval. Toronto, ON, Canada. 2003. P. 235–242.

9. Soni S., Sharaff A. Sentiment analysis of customer reviews based on hidden markov model // Proceedings of the 2015 International Conference on Advanced Research in Computer Science Engineering & Technology (ICARCSET 2015). Unnao. India. 2015. P. 1–5.

10. Malik V., Kumar A. Communication. Sentiment Analysis of Twitter Data Using Naive Bayes Algorithm // Int. J. Recent Innov. Trends Comput. Commun. 2018. V. 6. P. 120–125.

11. Mehra N., Khandelwal S., Patel P. Sentiment Identification Using Maximum Entropy Analysis of Movie Reviews // Stanford University: Stanford. CA. USA, 2002.

12. Wu H., Li J., Xie J. Maximum entropy-based sentiment analysis of online product reviews in Chinese // Automotive, Mechanical and Electrical Engineering. CRC Press: Boca Raton. FL. USA. 2017. P. 559–562.

13. Firmino Alves A.L., Baptista C.D.S., Firmino A.A., Oliveira M.G.D., Paiva A.C.D. A Comparison of SVM versus naive-bayes techniques for sentiment analysis in tweets: A case study with the 2013 FIFA confederations cup // Proceedings of the 20th Brazilian Symposium on Multimedia and the Web. João Pessoa. Brazil. 2014. P. 123–130.

14. Bordoloi M., Biswas S.K. Sentiment analysis: A survey on design framework, applications and future scopes // Artif. Intell. Rev. 2023. DOI: https://doi.org/10.1007/s10462-023-10442-2.

15. Chong W.Y., Selvaretnam B., Soon L-K. Natural language processing for sentiment analysis: an exploratory analysis on tweets // 2014 4th international conference on artificial intelligence with applications in engineering and technology. IEEE. 2014. P. 212–217.

16. Rajput A. Natural language processing, sentiment analysis, and clinical analytics // Lytras MD, Sarirete A (eds). Innovation in health informatics. Elsevier. Academic Press. 2020. P. 79–97.

17. Aggarwal C.C. Neural Networks and Deep Learning // Springer: Berlin. Germany. 2018.

18. Zhang L., Wang S., Liu B. Deep learning for sentiment analysis: A survey // WIREs Data Min. Knowl. Discov. 2018. V. 8. e1253.

19. Britz D. Recurrent Neural Networks Tutorial, Part 1–Introduction to Rnns. Available online: http://www.wildml.com/2015/09/recurrent-neural-networkstutorial-part-1-introduction-to-rnns.

20. Hochreiter S., Schmidhuber J. LSTM can solve hard long time lag problems // Proceedings of the Advances in Neural Information Processing Systems. Denver. CO. USA. 1996. P. 473–479.

21. Pandey A.C., Rajpoot D.S., Saraswat M. Twitter sentiment analysis using hybrid cuckoo search method // Inf. Process. Manag. 2017. V. 53. P. 764–779.

22. Лукашевич Н. В. Автоматический анализ тональности текстов: проблемы и методы // Интеллектуальные системы. Теория и приложения. 2022. Т. 26. № 1. С. 50–61.

23. Косых Н. Е. Применение модели дистилляций знаний BERT для анализа настроений текста//Вестник ВГУ. Серия: Системный анализ и информационные технологии. 2022. № 3. С. 139–151. DOI: https://doi.org/10.17308/sait/1995-5499/2022/3/139-151.

А.В. КУЗЬМЕНКО, В.С. КИРЕЕВ
Национальный исследовательский ядерный университет «МИФИ», Москва
kuzmenko_andrey2907@mail.ru

КЛАССИФИКАЦИЯ МЕТОДОВ ИЗВЛЕЧЕНИЯ РЕЛЯЦИОННЫХ ТРОЕК ИЗ ТЕКСТОВ НА ЕСТЕСТВЕННОМ ЯЗЫКЕ

В работе рассматриваются методы решения задачи извлечения реляционных троек из текстов на естественном языке. Авторами предложена классификация этих методов на четыре группы: конвейерные методы, методы на основе заполнения таблиц, методы, основанные на введении дополнительной маркировки текстовых последовательностей, методы на основе преобразования последовательности в последовательность (sequence-to-sequence). Приведены результаты сравнительного анализа указанных групп методов.

Ключевые слова: *обработка текстов на естественном языке, реляционная тройка, машинное обучение, глубокое обучение, seq2seq.*

Введение

Извлечение информации – это фундаментальная проблема обработки текста на естественном языке. Особый интерес у исследователей, в последнее время, проявляется к графам знаний неструктурированных, необработанных текстов. Ключевой технологией к их автоматическому построению является извлечение реляционных троек. Если рассматривать текст как носитель информации, то реляционные тройки выступают в нем строительными блоками. Они состоят из двух сущностей, связанных семантическим отношением в форме (субъект, отношение, объект). Сущностями могут являться люди, организации, местоположения и другие. Примеры отношений: человек-принадлежность, организация-местоположение. Так, отношение «лицо-принадлежность» означает, что конкретное лицо аффилированно с определенной организацией. Как правило, количество уникальных сущностей не ограничено, при это набор отношений фиксированного размера. В данной работе рассматриваются методы для решения именно такой постановки задачи.

Существующие исследования задачи извлечения реляционных троек можно разделить на четыре парадигмы (рис.1): 1) конвейерные методы в которых сначала распознаются сущности, а затем проводят классификацию

отношений; 2) методы на основе заполнения таблиц, которые представляют сущности и отношения с общими параметрами, но извлекают сущности и отношения отдельно; 3) методы, основанные на маркировке, рассматривающие эту задачу как проблему маркировки последовательностей и нуждаются в разработке сложной схемы маркировки; 4) методы на основе seq-to-seq, которые применяют модель seq-to-seq для прямого создания реляционных троек.

Рис. 1. Классификация методов извлечения реляционных троек

Конвейерные методы

Задача извлечения реляционных троек, в силу произвольного набора сущностей и константного набора отношений, интуитивно разделяется на две подзадачи. Первая − представляет из себя модифицированную задачу извлечения именованных сущностей. Вторая − классическая задача классификации. Именно такое рассуждение лежит в основе конвейерных методов. Они состоят из двух стадий. На первой извлекаются сущности или потенциальные кандидаты. На второй определяется тип семантического отношения.

В этой группе методов можно выделить два основных преимущества: первое − гибкость в выборе компонентов системы, второе − наличие промежуточных результатов, которые упрощают отладку системы. В [1] на стадии извлечения сущностей применяется поверхностный синтаксический анализ. Он идентифицирует ключевые элементы предложения, чем обеспечивает довольно надежный механизм текстового представления.

Для всех предложений, даже не грамматических, формируется структурное представление в виде неглубокого синтаксического дерева. В качестве, такого механизма в [1] используется созданная вручную система извлечения информации (Aone and Ramos-Santacruz, 2000), которая состоит из последовательности каскадных конечных автоматов, которые идентифицируют имена, словосочетания и ограниченный набор частей речи в тексте. Система также классифицирует словосочетания и имена существительные в зависимости от того, относятся ли они к людям, организациям и местам, тем самым создавая сущности. Таким образом, входные данные для системы извлечения отношений представляют собой неглубокий синтаксический анализ с именными словосочетаниями и именами, помеченными соответствующими типами сущностей. Альтернативный подход, основанный на правилах и шаблонах, представлен в работе [2]. Здесь анализируется корпус ACE-2004, в котором аннотаторы выделили пять синтаксически-семантических двумерных структур: предварительный модификатор, указание на принадлежность (притяжательный падеж), наличие предлога, шаблонность, глагольная форма. Для первых четырех в [2] описаны паттерны для их идентификации, некоторые включают семантическое сравнение типов, но большинство носят синтаксический характер. Более современный подход предлагается в работе [3], где применяется стандартная модель извлечения именованных сущностей, основанная на диапазонах. В ее основе лежит предварительно обученная модель типа BERT. Для предложения, состоящего из n токенов генерируется соответствующая ему последовательность векторов $X = \{x_1, x_2, \dots x_n\}$. Далее формируются все возможные комбинации вида $h_e(i,j) = [x_i; x_j; \varphi(j-i)]$, $i < j$; где i, j – порядковые номера токенов; φ – линейный оператор, отображающий разность индексов в вектор фиксированной размерности. Жадный перебор авторы ускоряют путем введения дополнительного гиперпараметра, ограничивающего максимальную разность индексов.

На второй стадии конвейерных методов задается вопрос, действительно ли выбранные пары являются семантически аффилированными. В [1] предлагаются ядерные методы извлечения отношений с функцией ядра на атрибутах деревьев синтаксического анализа. Авторы [2] придерживаются методологии моделей, идентифицирующей отношения между парами по признакам. В работе [3] для идентификации отношений используется, как и на первой стадии, еще один предобученный кодировщик типа BERT. Для всех комбинаций сущностей и отношений, найденных на первом этапе, модифицируется исходное предложение путем введения специальных токенов $\{\langle S{:}\, e_i\rangle, \langle /S{:}\, e_i\rangle, \langle S{:}\, o_i\rangle\ \langle /S{:}\, o_i\rangle\}$. Они показывают начало и конец сущностей.

Таким образом формируется модифицированная последовательность векторных представлений

$$\hat{X} = \Big\{\hat{x}_1, \hat{x}_2, \dots \hat{x}_{\langle S:e_i\rangle}, \hat{x}_{start(i)}, \dots, \hat{x}_{end(i)}, \hat{x}_{\langle \overline{S}:e_i\rangle}, \dots,$$

$$= \hat{x}_{\langle S:o_j\rangle}, \hat{x}_{start(j)}, \dots, \hat{x}_{end(j)}, \hat{x}_{\langle /S:o_j\rangle}, \dots\Big\}. \quad (1)$$

Финальным этапом является определение типа отношения из всех возможных комбинаций векторов $h_r(i,j) = [\hat{x}_{start(i)};\ \hat{x}_{start(j)}]$.

Декомпозиция задачи извлечения реляционных троек на последовательность двух отдельных подзадач: распознавание сущностей и извлечение отношений, упрощает выполнение задачи, однако такое разделение вынуждает игнорировать базовые зависимости между подзадачами внутри них. Извлечение отношений часто рассматривается как задача многоклассовой классификации пар сущностей, поэтому зависимости между парами игнорируются.

Методы на основе заполнения таблиц

Извлечение реляционных троек можно представить, как задачу заполнения таблицы. Впервые такой подход предложили в работе [4]. Он заключается в построении квадратной матрицы, где на пересечении индексов, соответствующих токенов находятся соответствующее этой паре отношение. Таким образом, идентифицировать сущностей теперь является не обязательным шагом, однако это также возможно. Таблицу можно усечь до треугольной, включая главную диагональ, поскольку она является полностью симметричной относительно главной диагонали. Иллюстрирует данный механизм рис. 2 [5].

	Mrs.	Tsutayama	is	from	Kumamoto	Prefecture	in	Japan	.
Mrs.	B-PER								
Tsutayama	⊥	L-PER							
is	⊥	⊥	O						
from	⊥	⊥	⊥	O					
Kumamoto	⊥	⊥	⊥	⊥	B-LOC				
Prefecture	⊥	Live_in→	⊥	⊥	⊥	L-LOC			
in	⊥	⊥	⊥	⊥	⊥	⊥	O		
Japan	⊥	Live_in→	⊥	⊥	⊥	Located_in→	⊥	U-LOC	
.	⊥	⊥	⊥	⊥	⊥	⊥	⊥	⊥	⊥

Рис. 2. Пример таблицы с извлеченными из предложения сущностями и отношениями

Метка в таблице присваивается слову в соответствии с его положением относительно соответствующей сущности. Отношения представлены их видами и направлениями. ⊥ обозначает пару без отношений, а → и ← обозначают отношения слева направо и справа налево соответственно.

Существуют различные стратегии заполнения таблицы. Так, в работе [5], эта проблема решается с помощью подхода к структурированному обучению на основе истории, который присваивает метки ячейкам одну за одной [5]. Процесс заполнения можно представить в следующем виде:

$$y^* = s(x, y)\,, \tag{2}$$

где x – исходная таблица; $Y(x)$ – все возможные присвоения в таблице; $s(x, y)$ – функция, оценивающая присвоение $y \in Y(x)$ к x.

Как можно заметить, эта функция является авторегрессионной, так как каждое новое добавленное отношение будет влиять на прогноз следующего. Ее можно записать как:

$$s(x, y, 1, i) = s_{local}(x, y, i) + s_{global}(x, y, 1, i), \tag{3}$$

где $s_{local}(x, y, i)$ – локальная функция оценки, которая оценивает назначение в i-й ячейке без учета других назначений; $s_{global}(x, y, 1, i)$ – глобальная функция оценки, которая оценивает присвоение в разрезе с 1-го по $(i - 1)$-е присвоение.

Таким образом, задача заполнения таблицы в [5] сводилась к поиску параметров модели f, аппроксимирующей функцию $s(x, y, 1, i)$, так, чтобы минимизировать ошибку между оценками $\hat{y}$ и априорными метками отношений y по некоторому выбранному критерию. В качестве входных данных для модели f авторы [5] предлагали набор локальных и глобальных признаков.

Альтернативный подход к заполнению таблицы предлагается в [6]. Нейронную сеть обучают выполнять одновременно две задачи: распознавать именованные сущности и определять тип отношения между ними. Интуитивно понятное преимущество такого метода над конвейерными – наличие меток именованных сущностей очень информативно для нахождения типа отношений и наоборот. Кроме того, отпадает явная необходимость в экспертах-лингвистах.

Архитектура предложенной в [5] нейросетевой модели представляет из себя двунаправленную рекуррентную нейронную сеть с двумя классифицирующими головами. Одна голова предназначена для идентификации типа сущности, вторая для определения типа отношения. Схожий способ заполнения таблицы представлен в [6]. Из наиболее заметных отличий здесь можно выделить следующие: 1) более продвинутая центральная единица вычислений – LSTM ячейка [7]; 2) шесть различных проходов нейрон-

ной сети вместо трех; 3) более сложные представления входных слов, учитывающие информации о форме слова, POS-тега и символах, из которых состоит слово; 4) использование синтаксических признаков, полученных при помощи синтаксических анализаторов, на базе нейросетевых моделей с кодер-декодер архитектурой.

Большим недостатком данной группы методов, на основании рассмотренных работ, является то, что минимальной единицей, в предложении является слово. А в случае составных сущностей и вовсе требуется дополнительное интеллектуальное разбиение на смысловые компоненты предложения.

Методы на основе маркировки

Все группы методов, представленные в этой работе, за исключением методов, основанных на маркировке, позволяют представлять, как объекты, так и отношения, однако, извлекают они их по отдельности и создают избыточную информацию. Группа методов, рассматриваемая в данном разделе, решает задачу извлечения реляционных троек путем их моделирования напрямую. Задача извлечения реляционных троек переформулируется в задачу прогнозирования, дополнительно введенных, тегов токенов предложения. Теги содержат информацию как о сущностях, так и о связях между ними.

Рис. 3. Метод тегирования, предложенный в работе [8]

Рассмотрим метод тегирования, предложенных в новаторской работе [8]. Каждому слову присваивается метка, которая способствует извлечению результатов. Тегом «O» (сокращенно Other) помечаются слова, независящие от извлеченных результатов. Остальные теги состоят из трех частей: положение слова в сущности, тип отношения и роль отношения. Позиция слова в субъекте и объекте также кодируется. Для этого используются знаки «BIES» (от Begin, Inside, End, Single). Извлеченные результаты представляются тройками $\{Entity_1, RelationType, Entity_2\}$. «1» означает, что слово принадлежит первому элементу реляционной тройки-субъекту,

2 – второму – объекту. Тип отношения задается из предопределенного набора. На рис. 3 [8] показан пример, иллюстрирующий данный метод тегирования. Входное предложение содержит две тройки: {United States, Country-President, Trump} и {Apple Inc, Company-Founder, Steven Paul Jobs}, где «Country-President» и «Company-Founder» – предопределенные типы отношений.

Такой подход тегирования подходит только для случаев неперекрывающихся сущностей. Интуитивно понятную модификацию, разрешающую проблему перекрытия предложили в [9]. Вместо последовательности тегов, формируется список последовательностей размера n, где n – длина предложения. Однако, за это приходится платить квадратичной сложностью работы алгоритма извлечения реляционных троек. Более продвинутый способ тегирования, решающий задачу перекрывающихся отношений, был предложен в [10]. Схема маркировки имеет двухуровневую структуру: тегировщик субъекта и тегировщик объекта, зависящий от отношения. Вначале запускается тегировщик субъекта, чтобы найти все возможные субъекты, а затем для каждого найденного субъекта применяется тегировщик объекта, специфичный для отношения, чтобы найти все релевантные отношения и соответствующие объекты.

Характерная черта моделей, реализующих подход маркировки, – архитектура типа кодировщик-декодер. Модель LSTM-LSTM-Bias, предложенная в [8], построена на базе двух LSTM сетей. Причем первая, выполняющая роль кодировщик, является двунаправленной. Исследователи [9] предложили использовать разновидность метода Марковских случайных полей - в качестве декодера. Еще одним отличием от предыдущего подхода является механизм «позиционного внимания», который, как утверждают авторы, позволяет создавать различные представления предложений в соответствии с позицией запроса, решая проблему моделирования различных последовательностей тегов предложения. Более современной и производительной с точки зрения качества является архитектура [10]. Авторы предлагают для кодирования контекстной информации использовать предварительно обученную модель BERT. В соответствие с двумя этапами маркировки декодер состоит из двух модулей: тегировщик объекта и набор тегов объектов для конкретных отношений. Модуль тегирования высокого уровня одновременно идентифицирует объекты, а также задействованные отношения по отношению к субъектам, полученным на более низком уровне. Оба модуля по своей сути представляют обычные сети прямого распространения.

Методы на основе моделей преобразования последовательностей

Следующий класс моделей, в последнее время набирающий популярность, основан на преобразовании последовательностей с единой нейросетевой архитектурой. Такие модели принято называть seq-to-seq (от англ. Sequence to sequence). Как и методы на основе маркировки, модели seq-to-seq представлены в виде кодировщик-декодер архитектур. Но в отличие от [8, 9], они более эффективны с точки зрения скорости работы, так как имеют меньшую вычислительную сложность. Одной из первых работ, реализовавших подход seq-to-seq является [11].

В кодировщике предложение переменной длины $s = [w_1, \dots, w_n]$, где w_i – i-е слово, а n – длина предложения, сначала преобразуется в матрицу $X = [x_1, \dots, x_n]$, где x_i – векторное представление i-го слова. После чего, матрица подается в Bi-LSTM. Для каждого i-го шага получают выход $o_i^E = [\overrightarrow{o_i^E} : o_{n-t+1}^E{}^{\leftarrow}]$, и скрытые состояния. Представление всего предложения получается путем конкатенация последних скрытых состояний, т.е. $s = [\overrightarrow{h_n^E} : h_n^E]^{\leftarrow}$. Также есть работа [12], где вместо конкатенации используют усреднение.

Декодер модели предназначен для формирования вектора, из которого уже непосредственно классифицируется элемент реляционной тройки. Он состоит из LSTM, механизма внимания и механизма копирования. Выход декодера o_j^D используется для декодирования элементов реляционной тройки. Если j принадлежит ряду 1,4,7… прогнозируется тип отношения, если 2, 5, 8… – субъект, 3, 6, 9… – объект.

Векторное представление отношения, субъекта или объекта, получившее наибольшую вероятность, используется в качестве входных данных для следующего временного шага v_{j+1}.

Модель CopyRL, предложенная в [11] имеет ряд недостатков – модель предсказывает векторное представление соответствующее предсказанному на предыдущем шаге субъекту, как показали в исследовании [12]. Во-вторых, модель не способна извлекать элементы реляционных троек, состоящих из нескольких слов. В-третьих, модель штрафуется за то, что предсказала реляционные тройки в отличном от заданного порядке, хотя в действительности должен наблюдаться инвариант к порядку.

Первые две проблемы позволяет решать модификация CopyMTL, предложенная в [12]. Их модель основана на многозадачном обучении, для прогнозирования элементов реляционной тройки с несколькими маркерами. Проблема маскирования решается путем отображения o_{j-1}^D и o_i^E в объединенное пространство признаков через один дополнительный нелинейный

слой. Хотя CopyMTL решает проблему прогнозирования реляционных троек, содержащих элементы из нескольких слов, в механизме копирования это никак не учитывается – выбирается слово с максимальной вероятностью, однако не учитывается инвариант порядка прогнозирования реляционных троек, что негативно влияет на обучение модели.

Сравнительный анализ представленных методов

Ниже в таблице (табл. 1) представлены свойства групп методов, описанных ранее. Выбранные свойства оценивались по наиболее продвинутым алгоритмам – представителям соответствующей группы.

Таблица 1

Результаты сравнительного анализа методов извлечения реляционных троек

Методы	Учет составных сущностей в тройках	Учет связей между извлекаемыми объектами	Низкая сложность работы алгоритма	Степень контроля обучения
конвейерные методы	+	-	+	+
методы на основе заполнения таблиц	-	+	-	+
методы, основанные на маркировке	-	+	-	-
методы на основе seq-to-seq	-	+	+	-

Выводы

В работе введена классификация на четыре группы методов извлечения реляционных троек из текстов на естественном языке. Описаны ключевые особенности каждого из подходов. Все они имеют свои преимущества и недостатки. Более того, для каждый из методов имеет различные реализации, также имеющие собственные как сильные, так и слабые стороны.

Программа дальнейших исследований будет включать в себя модифицирование, комбинацию конкретных представителей каждой группы методов для устранения их недостатков исходя из условий конкретной задачи.

Список литературы

1. Zelenko D., Aone C., Richardella A. Kernel methods for relation extraction // Journal of Machine Learning Research 2003, Vol.3. P. 1083–1106.

2. Chan S., Y., Roth D. Exploiting syntactico-semantic structures for relation extraction // Proceedings of the 49th Annual Meeting of the Association for Computational Linguistics: Human Language Technologies, 2011 P. 551–560.

3. Zhong Z., Chen D. A frustratingly easy approach for entity and relation extraction // Proceedings of the 2021 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, 2021 doi: 10.18653/v1/2021.naacl-main-5.

4. Miwa M., Sasaki Y. Modeling Joint Entity and Relation Extraction with Table Representation // Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP), 2014 P. 1858–1869.

5. Gupta P., Schutze H., Andrassy B. Table Filling Multi-Task Recurrent Neural Network for Joint Entity and Relation Extraction // Proceedings of COLING 2016, the 26th International Conference on Computational Linguistics: Technical Papers, 2016, P. 2537–2547.

6. Zhang M., Zhang Y., Fu G.. End-to-End Neural Relation Extraction with Global Optimization // Proceedings of the 2017 Conference on Empirical Methods in Natural Language Processing, 2017. P. 1730–1740.

7. Miwa M., Bansal M. End-to-end Relation Extraction using LSTMs on Sequences and Tree Structures // Proceedings of the 54th Annual Meeting of the Association for Computational Linguistics (Vol. 1: Long Papers), 2016. P. 1105–1116.

8. Zheng S., et al. Joint Extraction of Entities and Relations Based on a Novel Tagging Scheme // Proceedings of the 55th Annual Meeting of the Association for Computational Linguistics (Vol. 1: Long Papers), 2017. P. 1227–1236.

9. Dai D., et al. Joint Extraction of Entities and Overlapping Relations Using Position-Attentive Sequence Labeling // Proceedings of the AAAI Conference on Artificial Intelligence, 2019. P. 6300–6308.

10. Wei et al. A Novel Cascade Binary Tagging Framework for Relational Triple Extraction // Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics, 2020. P. 1476–1488.

11. Zeng et al. Extracting Relational Facts by an End-to-End Neural Model with Copy Mechanism // Proceedings of the 56th Annual Meetings of the Association for Computational Linguistic. (Vol. 1 Long Papers), 2018. P. 506–514.

12. Zeng D., Zhang H., Liu Q. CopyMTL: Copy Mechanism for Joint Extraction of Entities and Relations with Multi-Task Learning // Proceedings of the AAAI Conference on Artificial Intelligence, 2020. P. 9507–9514.

А.Ю. КАЛИНИНА, В.С. КИРЕЕВ
Национальный исследовательский ядерный университет «МИФИ»
vskireev@mephi.ru

ВИЗУАЛИЗАЦИЯ КОРПУСА ДОКУМЕНТОВ С ПОМОЩЬЮ ИЗВЛЕЧЕНИЯ СУЩНОСТЕЙ И СВЯЗЕЙ ПРЕДМЕТНОЙ ОБЛАСТИ НА ОСНОВЕ НЕЙРОСЕТЕВОЙ МОДЕЛИ ГЛУБОКОГО ОБУЧЕНИЯ T5

В данной работе проводилось изучение и анализ существующих методов извлечения сущностей и отношений из текстов на естественном языке, включая методы устранение кореферентности, методы извлечение сущностей, методы извлечения отношений. С использованием открытого датасета RURED была дообучена нейросетевая модель на основе T5 и применена на собранном датасете новостей РБК. Полученные отношения были визуализированы в виде графа знаний с использованием инструментов графовой базы данных Neo4j.

Ключевые слова: *глубокое обучение, обработка текстов на естественном языке, распознавание именованных сущностей, извлечение отношений, устранение кореферентности, T5, графовые базы данных, визуализация текстов.*

Введение

Появление сети Интернет и рост доступности текстовой информации привели к росту объёмов информации в неструктурированной форме. представление для применения в прикладных задачах. Структурирование текстовой информации в текстах на естественном языке необходимо для более эффективного и точного анализа данных, выявления скрытых закономерностей, трендов и паттернов в тексте, а также определения настроения и мнения людей.

Задача извлечения информации из текстов на естественном языке находят применение во многих областях − бизнес, наука, образование и другие сфер деятельности, где необходимо быстро обрабатывать и анализировать большие объемы информации.

Автоматизированные системы, способные извлекать и структурировать текстовую информацию, могут значительно упростить работу людей и повысить эффективность бизнес-процессов. Хранение и визуализация извлеченной информации также являются важными аспектами [1–4]. Хранение

позволяет сохранить данные для последующего использования, а визуализация помогает представить информацию в удобном и понятном виде. Сложность построения таких систем заключается в том, что качество понимания текста зависит от множества факторов: от языка, от национальной культуры, от стиля написания текста и т.п. Так, к основным сложностям можно отнести: раскрытие анафор, свободный порядок слов в предложении, неологизмы, омонимы.

Специфика текста как объекта формализации заключается в том, что он представляет собой выраженное знаковыми средствами естественного языка содержание. Средства выражения в нем выступают как форма этого содержания. Процесс осмысления текста – это такой процесс, который осуществляется не на языковом уровне, а на содержательном, где существенную роль играет интеллект человека, позволяющий производить перестройку предметной соотнесенности лексических значений слов и находить денотат, соответствующий данному сочетанию значений.

Денотат – основной структурный элемент, единица содержания текста, представляющая собой образ некоторого фрагмента действительности. Денотат языкового выражения является критерием его осмысленности, то есть осмыслено то, что может быть соотнесено с соответствующим фрагментом действительности, с определенной ситуацией. Этот процесс может быть рассмотрен на примере перехода от лексико-грамматической структуры текста к графу его денотатной структуры, являющегося способом отображения его содержания.

Граф – это средство представления содержания в виде семантической связи, это перекодировка, структуризация знания. В основе перекодирования лежит группировка, смысловая организация материала. В общем виде методика построения графа денотативной структуры заключается в том, что из текста выделяются объекты (денотаты), о которых говорится в тексте, и та информация, которая сообщается о них. Эта информация выражается в виде других объектов, связанных с первыми определенными отношениями. Имена выделенных объектов фиксируются в виде вершин графа, которые располагаются в определенной последовательности. Эта последовательность определяется представлением о переходе от темы к подтемам, от общего к частному, от целого к части.

При построении такого графа анализ текста производится глобально, то есть отдельные предложения не обязательно выступают в качестве единиц анализа. Поэтому расположение вершин графа может не соответствовать порядку следования объектов в тексте, а отражать скорее их объективное, предметное соотношение. Сама графическая форма делает структуру отно-

шений между элементами различных уровней текста наглядной и обозримой и способствует более полному и глубокому пониманию содержания текста.

Для построения графа в работе решались следующие задачи: устранение кореферентности (неоднозначности) в исходном тексте для поиска всех слов, обозначающих одну и ту же сущность; поиск именованных сущностей (денотатов) в тексте; поиск связей между сущностями.

Подходы к решению задач при построении графа знаний

Для решения задач распознавания и извлечения информации из текстов используются два главных подхода: основанный на правилах (rule-based) и основанный на машинном обучении (machine learning). Стоит отметить, что в настоящее время появляется всё больше гибридных подходов, учитывающих достоинства обоих подходов.

Также стоит отметить, что в последние годы приобрел популярность метод трансферного обучения моделей. Цель трансферного обучения – применение знаний, полученных благодаря решению одной задачи, к другой, но схожей задаче. Такой подход позволяет получить более точные модели, экономя время и вычислительные ресурсы. При переносе обучения переносятся признаки, усвоенные при решении другой задачи, вместо того чтобы тренировать модели с нуля.

В лингвистике кореферентность – это отношение между частями высказывания, которые обозначают один и тот же внеязыковой объект или ситуацию. К настоящему времени разработано множество систем по разрешению кореферентности. Чаще всего, они используют подходы машинного обучения, и улучшают их с помощью различных лингвистических и концептуальных признаков. Ключевыми типами моделей являются попарная модель (mention-pair model) [5], модель ранжирования (ranking model) и сущностная модель (entity-based model) [6]. Современные исследования направлены на методы машинного обучения «без учителя» [7] и сущностные модели [8].

В качестве основного решения для задачи устранения кореферентности в текстах использовалась модель neuralcoref от компании Hugging Face. Neuralcoref была обучена на OntoNotes Release 5.0. Пример работы данной модели представлен на рис. 1.

Задача извлечения именованных сущностей (Named Entity Recognition, NER) состоит в распознавании в тексте именованных сущностей (которыми являются слова и словосочетания) и их классификации по предопре-

деленным категориям. Полное решение задачи распознавания именованной сущности в общем случае включает [9]: нахождение сущности в тексте (нахождение в тексте координат начала и конца сущности); определение категории сущности; связывание сущности с денотатом (называемым лицом/объектом), если именованная сущность является именем собственным. Оценка качества извлечения системой именованных сущностей обычно проводится на размеченном вручную корпусе. Именованная сущность определяется своими границами (входящими в неё словами) и типом.

Рис. 1. Пример работы модели neuralcoref

Задача извлечения именованных сущностей часто решается вместе с задачей извлечения отношений (Relation Extraction, RE), суть которой состоит в выделении в тексте пар сущностей, которые могут быть связаны друг с другом по смыслу. Если заранее заданы классы отношений, то говорят о задаче классификации отношений (Relation Classification, RC) – сопоставлении каждой паре сущностей конкретного класса отношения или распределения вероятностей классов. Размеченные отношения предоставляют расширенные знания о смысловых связях между сущностями в тексте. Выделенные данные в дальнейшем структурируются или визуализируются с целью их последующего анализа.

Имеющиеся методы решения задачи RE можно также разделить на две группы. К первой группе относятся методы, которые требуют большого количества человеческого труда, заключающегося в ручном задании правил (например, на основе регулярных выражений, деревьев синтаксического разбора и т.д.) и создании словарей для предметной области. Пример такого метода описан в [9]. Методы, основанные на построении некоторого векторного представления для каждой пары сущностей в документе и обучение классификатора на основе данного представления рассматриваются в [10].

Чаще всего сущности и их отношения представляют в виде так называемых троек, которые указывают на однозначные факты о сущностях. Тройка (obj, subj, r) подразумевает, что сущность obj связана семантическим отношением r с другой сущностью subj. Графы 20 знаний (Knowledge graphs, KG), такие как DBpedia [11] или Knowledge Graph [12], являются примерами таких представлений.

Распространенной метрикой оценки качества извлечения сущностей и связей служит $F1$-мера − соотношение между точностью и полнотой, которая определяется по формуле:

$$F_1 = 2\frac{TP}{TP+FP+FN}, \quad (1)$$

где, TP (true positive) − количество меток, верно соотнесённых категории; FP (false positive) − количество меток, неверно соотнесённых категории; FN (false negative) − количество меток, неверно не соотнесённых категории.

Значения F1-меры для подходов, основанных на CNN, RNN, BERT приведены в [13]. В качестве данных использовался набор Semeval 2010 Task8. Видно, что модели, основанные на BERT, показывают лучшие результаты – 87.5–90.2 %. Предполагается, что CNN лучше выделяет кратковременные зависимости (между близко расположенными токенами), в то время как LSTM выделяет долговременные зависимости и дополняет CNN.

T5 (Text-to-Text Transfer Transformer) – нейросетевая модель архитектуры типа Transformer Decoder для понимания и генерации текста. Она была анонсирована в работе от Google [14]. Для решения задачи извлечения отношений между именованными сущностями в данной работе использовалась русскоязычная T5 модель rut5-base, обученная Сбербанком.

Инструментальные средства визуализации графов

Для визуализации графов существует множество фреймворков, например:

Graphviz − это пакет программного обеспечения с открытым исходным кодом для визуализации графов. Он предоставляет набор инструментов и

библиотек для создания и отображения графов на основе их структуры и связей. Graphviz поддерживает различные форматы графов и обладает широкими возможностями настройки визуализации.

Gephi − это открытое программное обеспечение для визуализации и анализа графов. Он предоставляет интуитивно понятный интерфейс и богатый набор инструментов для создания, редактирования и визуализации графов. Gephi также позволяет применять различные метрики и алгоритмы для анализа и исследования графовых структур.

NetworkX − это библиотека Python для работы с графами. Она предоставляет удобные методы и функции для создания, манипулирования и визуализации графов. NetworkX также обладает богатым набором алгоритмов и методов анализа графов.

Neo4j − это графовая база данных, которая позволяет хранить и оперировать большими объемами графовых данных. Она предоставляет собственный язык запросов (Cypher) для выполнения сложных операций с графами. Neo4j также обладает инструментами для визуализации и анализа графов [15]. В данной работе было принято решение использовать графовую СУБД Neo4j.

В отличие от других noSQL баз данных, Neo4j объединяет данные в том виде, в котором они хранятся, что позволяет им проходить через соединения в более быстром порядке. Графовая платформа Neo4j построена на базе собственной графовой базы данных Neo4j, которая поддерживает транзакционные приложения и графическую аналитику. Любой запрос Cypher, который изменяет граф данных, представляет собой транзакцию и всегда либо выполнится полностью, либо не выполнится вовсе. Сохраняет транзакции ACID для полностью последовательных и надежных данных, идеально подходит для постоянно работающих глобальных корпоративных приложений.

Neo4j предоставляет гибкую и простую модель данных, которую можно легко модифицировать в соответствии с приложениями и отраслями, обеспечивает масштабирование с использованием распределенных аппаратных кластеров, использует собственный язык графовых запросов Cypher, который обеспечивает наиболее эффективный и выразительный способ описания запросов отношений. К недостаткам БД Neo4J можно отнести, то, что она занимает достаточно много места на диске, по сравнению с реляционными СУБД, кроме того. при выполнении простых запросов производительность ниже, чем в реляционных базах.

Полученные результаты

На сегодняшний день существует достаточно много датасетов общего назначения на разных языках (CONLL-2003, MUC-6, OntoNotes 5.0 и т.д.). Для выделения именованных сущностей использовалась модель rubert-base-cased, обученная на датасете RURED. RURED [16] — набор данных на русском языке, который содержит более 536 аннотированных текстов, в них размечено более 5000 отношений и 22000 именованных сущностей. Именованные сущности размечены по схеме Ontonotes [17]. Использовались тексты из корпуса Lenta.ru с тегом «Экономика». Всего в датасете размечены 28 типов сущностей и 28 типов отношений. Аннотация отношений в основном внутри предложений.

Рис. 2. Пример визуализации извлеченных отношений из корпуса новостей с помощью Neo4j

В данной работе было принято решение на этом этапе ограничить сущности до ORG, PER, GPE, DATE, MONEY, PROFESSION. Сущность EVENT не рассматривается из-за того, что в датасете RURED представлены достаточно тривиальные события, которые не представляют ценную информацию о новости. Для дополнительного выделения событий из текстов, модель rut5-base была дообучена на собранном вручную датасете. В

режиме использования модели на вход подается предложение с выделенными именованными сущностями, на выходе модель генерирует события между этими сущностями. Для данных событий выбирается тег EVENT.

Практические исследования проводились на языке Python 3.8. Для проведения экспериментов и реализации спроектированной архитектуры нейронной сети использовался фреймворк PyTorch, описанный выше. Дообучение нейросетевых моделей производилось на ноутбуке с видеокартой NVIDIA GeForce GTX 1660 Ti 16Gb.

Для дообучения моделей использовалась платформа Hugging Face. На ней в открытом доступе находится коллекция готовых современных предварительно обученных моделей. Для демонстрации концепции был собран датасет новостей с сайта РБК по тегу «Сбербанк». На рис. 2 представлен результат визуализации одного из полученных таким образом отношений.

Выводы

В данной работе был построен процесс для визуализации корпуса текстов в виде графа знаний с использованием нейросетевых алгоритмов извлечения именованных сущностей и связей между ними.

В качестве предметной области для проведения экспериментов была выбрана область финансов – использовались новости с сайта РБК по тегу компании, и акции, находящиеся в обороте на Московской Бирже, относящиеся к данной компании. Извлечение и визуализация отношений производилась с использованием языка Python и графовой СУБД Neo4j.

Список литературы

1. Voronov M., Pimenov V., Formalization of regulatory texts, Informatics and Automation, 2021, Issue 20, volume 3, 562–590. [Электронный ресурс] / URL: https://www.mathnet.ru/links/10da81377ffaadb957d06122abf1af25/trspy1153.pdf
2. Новиков А.И. Семантика текста и ее формализация - Москва: Наука, 1983. - 215 с.
3. McCusker James P., McGuinness Deborah L., Erickson John S., Chastain Katherine, What is a Knowledge Graph? [Электронный ресурс] / URL: https://www.authorea.com/users/6341/articles/107281-what-is-a-knowledge-graph/_show_article.
4. Message Understanding Conference [Электронный ресурс]: Википедия. Свободная энциклопедия. / URL: https://en.wikipedia.org/wiki/Message_Understanding_Conference.
5. Uryupina Olga, Moschitti Alessandro. State-of-the-Art Mention-Pair Model for Coreference Resolution [Электронный ресурс] / URL: https://aclanthology.org/S15-1034.pdf.

6. Vincent Ng. Supervised Noun Phrase Coreference Research: The First Fifteen Years // Proceedings of the 48th Annual Meeting of the Association for Computational Linguistics. –Uppsala, Sweden: Association for Computational Linguistics, 2010. – July. – P. 1396–1411.

7. Xuezhe Ma, Zhengzhong Liu, Eduard Hovy. Unsupervised Ranking Model for Entity Coreference Resolution // Proceedings of NAACL- 2016. – San Diego, California, USA,2016. – June.

8. Clark Kevin, Manning Christopher D.. 2015. Entity-Centric Coreference Resolution with Model Stacking. [Электронный ресурс] / URL: https://aclanthology.org/P15-1136/.

9. Автоматическая обработка текстов на естественном языке и анализ данных: учеб.пособие / Большакова Е.И., Воронцов К.В., Ефремова Н.Э., Клышинский Э.С., Лукашевич Н.В., Сапин А.С. – М.: Изд-во НИУ ВШЭ, 2017. – 269 с.

10. Сорока Евгения. Предобученные модели. Что это такое, почему они важны и где их взять. [Электронный ресурс] / URL: https://robotdreams.cc/blog/115-predobuchennyemodeli.

11. DBpedia [Электронный ресурс]: Википедия. Свободная энциклопедия. / URL: https://ru.wikipedia.org/wiki/DBpedia.

12. Singhal. Amit Introducing the Knowledge Graph: things, not strings [Электронный ресурс] / URL: https://blog.google/products/search/introducing-knowledge-graph-things-not/65.

13. Nasar Z., Jaffry S. W., Malik M. K. Named Entity Recognition and Relation Extraction: State-of-the-Art Article in ACM Computing Surveys · February 2021.

14. Pandey, Santosh & Joshi, Erika & Maharjan, Manish & Karki, Nissan. (2018). A research on Architectural and Performance Comparison of Relational Database, NoSQL and Graph database (Neo4j). 10.13140/RG.2.2.33279.25762/1.

15. Gordeev, Denis & Davletov, A. & Rey, A. & Akzhigitova, G. & Geymbukh, G.. (2020). Relation extraction dataset for the russian. 348-360. 10.28995/2075-7182-2020-19-348-360.

16. Pradhan, Sameer & Hovy, Eduard & Marcus, Mitchell & Palmer, Martha & Ramshaw, Lance & Weischedel, Ralph. (2007). OntoNotes: A Unified Relational Semantic Representation.. Int. J. Semantic Computing. 1. 517-526.

Е.В. КУЛЯБИНА, Т.В. КУЛЯБИНА, В.В. МОРОЗОВА, В.Ю. МОРОЗОВ
Всероссийский научно-исследовательский институт метрологической службы, Москва
kuliabina@vniims.ru

ВОПРОСЫ ИССЛЕДОВАНИЯ И ВЫБОРА МЕТОДОВ И СРЕДСТВ ОБЕСПЕЧЕНИЯ ТОЧНОСТИ И ВАЛИДАЦИИ ПРИ СОЗДАНИИ ВИРТУАЛЬНОГО ОБРАЗЦА ЖИВОЙ КЛЕТКИ ДЛЯ МОДЕЛИРОВАНИЯ ВНУТРИКЛЕТОЧНЫХ ПРОЦЕССОВ МЕТОДАМИ НЕЙРОИНФОРМАТИКИ

Рассматриваются вопросы создания средств и методов исследования виртуальной модели живой клетки методами нейроинформатики, с учетом создания средств и методов метрологического обеспечения для получения точных результатов измерений, последующего прогнозирования поведения органелл клетки, последствий воздействия новых вирусов на живую клетку. Будут приведены подходы к исследованию ответов клетки на различные условия среды (значение pH, избыток/недостаток микроэлементов, нарушения функционирования органелл, влияние температуры и т.д.); моделирование поведения различных компартментов живой клетки. Будут показаны методы обеспечения метрологической прослеживаемости результатов измерений.

Ключевые слова: *нейроинформатика, виртуальная модель живой клетки, валидация, методики измерений, стандартные образцы, метрологическая прослеживаемость.*

Введение

Методы нейроинформатики являются необходимым условием разработки научного базиса и вообще самой возможности реализации проекта создания виртуальной модели живой клетки. Методы получения точных результатов анализа функционирования различных компартментов живой клетки, правил и законов ее жизнедеятельности неразрывно связаны с применением подходов метрологического обеспечения. Благодаря имеющийся основам, к которым прослеживаются все измерения – фундаментальным физическим константам и единицам физических величин Международной системы единиц SI, реализованных в Международном бюро мер и весов

(Bureau International des Poids et Mesures, BIPM), мы можем гарантировать точность и достоверность получаемых результатов, их метрологическую прослеживаемость [1].

Современное состояние проблематики исследования

В настоящее время известно много работ зарубежных авторов, посвященных проблемам бимолекулярного моделирования органелл клетки, получению высокоточной структуры белков на основе компьютерной симуляции молекулярной динамики [2–4]. Разработана динамическая модель работы рибосомы, синтезирующей молекулу белка, в которой просчитывалось взаимодействие около 2,5 млн атомов [5].

Бесценный вклад в рассматриваемые нами вопросы внесли исследования Харольда Моровица, посвященные выяснению взаимосвязи влияния энергетических флуктуаций на метаболизм клетки, описание принципа наличия свободной энергии для понимания возникновения, организации и сохранения жизни [6, 7]. Харольд Моровиц рассмотрел моделирование целой клетки, составил алгоритм, моделирующий бактерию Mycoplasma (1984 г.), от которого начинается история развития моделирования клеток [8, 9].

Динамическое моделирование вируса-сателлита табачной мозаики, выполненное коллективом авторов, является на наш взгляд фундаментальной вехой в компьютерном моделировании процессов жизнедеятельности клетки [10]. Американские биоинформатики впервые в мире построили динамическую компьютерную модель живого организма на атомном уровне. Для моделирования был выбран один из самых простых известных вирусов – вирус-сателлит табачной мозаики. Его размер составляет всего около 20 нм. Вся модель в целом содержит более миллиона атомов. Их взаимное расположение и движение рассчитывалось с учетом сил межатомного взаимодействия, как это обычно делается при моделировании макромолекул. Расчет, выполненный в американском Национальном центре суперкомпьютерных приложений (NCSA), позволил в течение короткого отрезка модельного времени следить за динамикой вируса, когда он представлен самому себе. В результате были уточнены и механические свойства, и внутреннее строение вирусной частицы.

Следует отметить и работы российских ученых и исследователей, в том числе, но не ограничиваясь – исследования ученых Сибирского отделения Российской академии наук в области компьютерного моделирования и разработки целого виртуального организма на основе C. Elegans [11]; структурно-функциональные исследования для направленного конструирования

новых лекарственных средств, проводившиеся в Государственном Научном Центре ФГБУН ИБХ РАН [12, 13].

В целях анализа и использования для метрологического обеспечения биомедицинских измерений виртуальные модели пока не исследовались, и данная работа является пионерской.

Постановка задачи

Причиной, побудившей авторов к постановке темы проекта, явилась пандемия КОВИД-19, имеющая самые печальные последствия для всего мирового сообщества. Во время уже первых дней пандемии стала совершенно очевидной необходимость достижения высокой скорости принятия решений о госпитализации, точности идентификации вируса SARS-CoV-2, оценки вирусной нагрузки на организм. Метрологи многих стран объединившись разработали Дорожную карту по метрологической готовности к реагированию на новые вероятные пандемии инфекционных заболеваний [14]. Стала понятной острая необходимость в очень быстрой отработке реакции клеток организма человека на воздействие уже изученного и идентифицированного штамма вируса, а также еще не изученных новых штаммов и новых, возможных вирусов. Для обеспечения достоверной идентификации нужны надежные основы для сравнения, которыми могут явится стандартные образцы штаммов вирусов, например.

Рассмотрим существующие в системе обеспечения единства измерений стандартные образцы состава, свойств, структуры веществ и материалов и методики измерений физических величин живых объектов, которые позволяют обеспечивать единство измерений во многих областях деятельности человека, в том числе и в медицине.

Для обеспечения единства измерений в сфере здравоохранения для целей идентификации и измерений параметров свойств живого объекта необходимо порядка 10 тысяч образцов субстанций в различных матрицах (стандартных образцов, государственных стандартных образцов или ГСО). Начиная с самых простых матриц – высокочистые растворители (вода, этанол, метанол и т.п.) и, заканчивая биологическими жидкостями (моча, пот, желчь, цереброспинальная жидкость…) и тканями (кровь, включая плазму и сыворотку, мышечные волокна, эпителий, хрящевая ткань, нейроны…). Для части важных для анализа в организме человека веществ, лекарственных субстанций – нейролептиков, сильнодействующих веществ, наркотических субстанций создание ГСО вообще невозможно (по причине строгости законодательства). И тем более сложно оценить достоверность идентификации и точность измерений концентрации данных веществ в организме.

Стандартные образцы свойств белков, последовательностей нуклеотидов РНК, ДНК создаются довольно сложными путями и сообщают нам уверенность только о числовом или качественном значении не более, чем одного-двух компонентов, чего совершенно недостаточно для понимания функционирования живой клетки. Любой стандартный образец применяется в соответствии с руководством по применению или методикой измерений. Очевидно, что, как и стандартных образцов, так и методик измерений явно недостаточно для решения вышеозначенных проблем.

Наша работа призвана решить вышеуказанные задачи.

Предлагаемые методы и подходы

Искусственной нейронной сети в данной работе отводится основная роль.

Так, первым шагом выясняются-формулируются-создаются законы взаимодействия компартментов и субкомпартментов клетки с применением рекуррентных сетей для автоматического анализа текстов, в которых описываются известные законы и характеристики взаимодействия. Сюда включаются аспекты моделирования структуры применительно к структурной биологии [14], аннотация геномов [15], вероятно также и предсказание эффекта генетических мутаций [16].

Далее с учетом аналитического обзора информации, полученной ранее, происходит обучение нейросетей, моделирование внутриклеточных процессов.

Получение точных характеристик параметров жизнедеятельности клетки реализуется посредством применения средств измерений, перечень которых включает, но не ограничивается: ЯМР-спектрометром; масс-спектрометром высокого разрешения с тандемным квадруполем и времяпролетным детектором, масс-спектрометром с индуктивно-связанной плазмой, с диапазоном определяемых масс, начиная от 5 Да и до 2250 Да; высокоэффективными жидкостными и газовыми хроматографами; pH-метрами; прецизионными термометрами; высокоточными лабораторными весами и т.д. Все эти средства измерений должны быть утвержденных типов, внесены в Федеральный информационный фонд по обеспечению единства измерений [18], иметь действительную поверку, только тогда можно гарантировать, что результаты измерений, получаемые с их применением, соответствуют действительным и указанные приборы можно применять для получения точных результатов анализов.

Обеспечивать метрологическую прослеживаемость результатов измерений, так же, как и валидировать методики измерений мы предлагаем отдельно для каждого элемента системы клетки. Так, например, количественное содержание нуклеиновых кислот можно проследить к существующим референтным материалам [19]. Последовательность нуклеотидов прослеживают к Кембриджской референсной (эталонной) последовательности (CRS) – первой секвенированной последовательности митохондриальной ДНК (мтДНК) человека. Была получена в 1981 г. в Кембридже под руководством нобелевского лауреата Фредерика Сенгера и представляет из себя текст из 16 569 нуклеотидов. Кембриджская эталонная последовательность (Cambridge Reference Sequence, CRS) принята за эталон. Отклонения от этого эталона называют мутациями и обозначают комбинацией числа (номера нуклеотида) и буквы (названия нуклеотида). Например, 1651C означает, что нуклеотид под номером 1651 (в «стандартной» CRS это тимин, T) заменен на цитозин (C). Тут прослеживаемость осуществляется через стандартные образцы национальных метрологических институтов – в России это ФГБУ «ВНИИМС», в США – NIST.

Стандартизация свойств и валидация методов определения, например, свойств клеток вирусов представляет настоящий вызов для метрологов [20]. Так, в материале [21] представлены результаты исследований по разработке стандартного образца (RM) вирусоподобных частиц, прослеживаемого до Международной системы единиц (SI).

В настоящее время создать такой образец уже представляется возможным, так как существуют методы анализа, позволяющие оценить, как чистоту материала, путем определения содержания родственных примесей, воды, остаточных органически растворителей, летучих органических соединений, неорганических примесей, так и оценить неопределенность образца. Если говорить о структуре то, например, возьмем в рассмотрение трискелион (пептид), который собирается в вирусоподобный икосаэдр, о которых сообщалось в другом месте [19], то трискелион синтетически доступен, предсказуемо собирается в вирионоподобные частицы.

После того как определены все, возможные для контроля и значимые элементы клетки, и показана воспроизводимость и прослеживаемость их свойств, методики успешно прошли процедуру валидации, на первое место опять выступает нейросеть. За последние десятилетия развилось представление о живой клетке как о химическом реакторе с массивно взаимосвязанным множеством бистабильных каталитических процессов. Инструментом, описывающим основные свойства такой системы, является теория нейронных сетей. Этот подход позволяет рассматривать клетку как объект, обладающий набором стереотипных вариантов поведения.

Выводы

Предложены подходы к созданию средств и методов исследования виртуальной модели живой клетки методами нейроинформатики. Предложенная парадигма обеспечения точных и прослеживаемых результатов измерений свойств элементов клетки для целей создания ее виртуальной модели видится многообещающей как в научном, так и в практическом плане.

Применяемые средства и методы, их валидация являются необходимыми условиями разработки виртуальной модели.

Результаты могут быть применены для:

- сокращения наработки необходимых для исследований организма симуляций поведения биологического объекта с «нескольких лет» до «нескольких минут»;
- возможности перебора миллионов изменяющихся параметров условий анализа и сопутствующих факторов в течение нескольких часов, а не лет;
- контроля метрологического состояния средств измерений, применяемых в биоанализе, без применения дефицитных (не существующих, и которые в ближайшее время не удастся создать) ГСО;

обеспечения высокоточных и достоверных результатов исследований живой клетки.

Список литературы

1. Кулябина Е.В., Морозова В.В., Морозов В.Ю., Кулябина Т.В. О возможности создания цепи метрологической прослеживаемости результатов исследований качественных свойств биологических субстанций // Законодательная и прикладная метрология. 2022. № 5. С. 39–45.

2. Kryshtafovych A., Schwede T., Topf M., Fidelis K., Moult J. Critical Assessment of Methods of Protein Structure Prediction (CASP) – Round XIV // Proteins. 2021. V. 89. No.12. P. 1607–1617.

3. Mirdita M., Schütze K., Moriwaki Y. et al. ColabFold: making protein folding accessible to all // Nature Methods. V. 19. 2022. P. 679–682.

4. Yang Z., Zeng X., Zhao Y. et al. AlphaFold2 and its applications in the fields of biology and medicine // Signal Transduction and Targeted Therapy. 2023. V. 8. No. 115.

5. Munro J.B., Altman R.B., Tung Ch.-Sh., Sanbonmatsu K.Y., Blanchard S.C. A fast dynamic mode of the EF-G-bound ribosome // The EMBO Journal. 2010. V. 29. No. 4. P. 770–781.

6. Morowitz H.J., Smith E. Energy flow and the organization of life // Complexity. 2007. V. 13. No. 1. P. 51–59.

7. Morowitz H.J. A Theory of Biochemical Organization, Metabolic Pathways, and Evolution // Complexity. 1999. V. 4. No. 6. P. 39–53.

8. Morowitz H.J., Wallace D.C. Genome size and life cycle of the mycoplasma // Annals of the New York Academy of Sciences. 2006. V. 225. No. 1. P. 62–73.

9. Maniloff J., Morowitz H.J. Ultrastructure and Life Cycle of Mycoplasma Gallisepticum A5969 // Annals of the New York Academy of Sciences. 2006. V.143. No. 1. P. 59–65.

10. Freddolino P.L., Arkhipov A.S., Larson S.B., McPherson A., Schulten K. Molecular dynamics simulations of the complete satellite tobacco mosaic virus // Structure. 2006. V. 14. No.3. P. 437–449.

11. Пальянов А.Ю., Пальянова Н.В. О перспективах исследования и компьютерного моделирования нейронных механизмов управления движением в организме C. Elegans // Марчуковские научные чтения – 2019: Тезисы Международной конференции «Актуальные проблемы вычислительной и прикладной математики». 2019. Новосибирск: ИПЦ НГУ. 168 с.

12. Головин А.В. и др. Эволюция каталитических центров антител путём виртуального скрининга широкого репертуара мутантов на суперкомпьютере // Доклады Академии наук. 2017. Т. 475. № 1. С. 94–98.

13. Габибов А.Г. Белки и пептиды в постгеномную эру. Структурно-функциональные исследования для решения фундаментальных задач и направленного конструирования инновационных лекарственных средств // Завершенный грант РНФ 14-50-00131. 2014–2018 гг.

14. Braybrook J., Hugget J., Melanson J.E. et al. CCQM Roadmap to Metrology Readiness for Infectious Disease Pandemic Response.

15. Cai Y.-D., Liu X.-J., Xu X., Zhou G.-P. Support vector machines for predicting protein structural class // BMC Bioinformatics. 2001. V. 2. No. 3.

16. Woodcroft B.J., Boyd J.A., Tyson G.W. OrfM: a fast open reading frame predictor for metagenomic data // Bioinformatics. 2016. V. 32. No. 17. P. 2702–2703.

17. Adzhubei I., Jordan D.M., Sunyaev S.R. Predicting functional effect of human missense mutations using PolyPhen-2 // Current Protocols. 2013.

18. Федеральный информационный фонд по обеспечению единства измерений. https://fgis.gost.ru/fundmetrology/registry/4.

19. De Santis E. et al. Antimicrobial peptide capsids of de novo design // Nature Communications. 2017. V. 8.

20. Burns J.R. et al. DNA origami inside-out viruses // ACS Synthetic Biology. 2018.

21. Briones A. et al. An SI-traceable reference material for virus-like particles // iScience. 2022. V. 25. No. 5.

А.А. БОЛОТНИКОВА, Н.П. ШЛАПАК
Обнинский институт атомной энергетики НИЯУ МИФИ
bolotnikovaaa@oiate.ru

ПРИМЕНЕНИЕ НЕЙРОННЫХ СЕТЕЙ В ПРОГНОЗИРОВАНИИ ИЗМЕНЕНИЯ ИЗОТОПНОГО СОСТАВА ТВС РЕАКТОРА ВВЭР-1000

Рассматривается возможность применения нейронных сетей в решении задачи прогнозирования изотопного состава ядерного топлива. Предложен, разработан и протестирован алгоритм, основанный на рекуррентной нейронной сети, способный по таким параметрам свежего топлива, как обогащение и массовое содержание оксида гадолиния в твэгах, прогнозировать изотопный состав ТВС в запрашиваемый момент времени. Данный алгоритм можно использовать для проведение быстрых предварительных расчетов.

Ключевые слова: *рекуррентные нейронные сети, прогнозирование, ядерное топливо, изотопный состав.*

Введение

Возможность протекания цепной реакции в ядерном энергетическом реакторе (далее – ЯЭР) определяется эффективным коэффициентом размножения нейтронов k_∞, который зависит от изотопного состава ядерного топлива [1], который непрерывно изменяется как во время нахождения топлива в ЯЭР, так и после, вследствие протекания реакции деления урана и радиоактивного распада ее продуктов.

Глубина выгорания ядерного топлива является важным показателем, определяющим экономическую эффективность топливной кампании. Для ее увеличения в реакторах ВВЭР-1000 применяется уран высокого обогащения (до 5 %), из-за чего в начале кампании образуется высокая избыточная реактивность [2], требующая компенсации из соображений безопасности. С этой целью в часть тепловыделяющих элементов (твэлов) добавляют вещество с высоким сечением поглощения нейтронов, выгорающее к концу кампании – выгорающий поглотитель. В реакторах ВВЭР-1000 в качестве выгорающего поглотителя применяют оксид гадолиния Gd_2O_3 [3] в форме гомогенной добавки к оксиду урана UO_2. Твэлы с такой добавкой называют тепловыделяющими элементами с гадолинием (твэгами). В тепловыделяющих сборках (ТВС) на них заменяется часть твэлов. Соотношение урана и

гадолиния в топливе оказывает влияние на его эксплуатационные характеристики, также от него сложным образом зависит глубина выгорания [4].

В процессе глубокого выгорания топлива образуются высокоактивные актиниды: плутоний, америций, нептуний и др. Их накопление необходимо принимать во внимание при планировании операции переработки отработавшего ядерного топлива и утилизации отходов переработки [2]

Поэтому задача прогнозирования изотопного состава ядерного топлива с различным соотношением урана и гадолиния является актуальной. Она принадлежит к классу задач моделирования нейтронно-физических процессов. Для моделирования используется в основном статистический подход, основанный на методе Монте-Карло, к недостаткам которого можно отнести низкую скорость работы и требование больших вычислительных мощностей [5]. В тоже время, поставленную задачу можно рассматривать как прогнозирование временного ряда, для которого целесообразным является использование рекуррентной нейронной сети [5–8].

Данная работа является развитием исследований [5–8]. Рассматривается возможность прогнозирования изотопного состава всей ТВС.

Постановка задачи и подготовка данных

Была поставлена задача по составу свежего топлива в ТВС определять его изменение в любой момент времени. Считалось, что данное изменение определяется данными об обогащении твэлов, массовом содержании оксида гадолиния в твэгах, начальном содержании изотопов (список приведен в табл. 1), k_∞ в начале кампании.

Таблица 1

Прогнозируемые изотопы

№	Обозначение	№	Обозначение	№	Обозначение	№	Обозначение
1	U235	8	Pu239	15	Am243	22	Gd152
2	U237	9	Pu240	16	Am244	23	Gd154
3	U238	10	Pu241	17	Cm242	24	Gd155
4	Np237	11	Pu242	18	Cm243	25	Gd156
5	Np238	12	Pu243	19	Cm244	26	Gd157
6	Np239	13	Am241	20	Cm245	27	Gd158
7	Pu238	14	Am242	21	Cm246	28	Gd160

Рассматривалась стандартная ТВС реактора ВВЭР-1000 с размещением 12-ти твэгов по углам шестигранника в третьем и восьмом гексагональных кольцах. Gd_2O_3 смешан равномерно с UO_2. Прогнозировалась кампания до 3360 эффективных суток (эфф. сут.), хотя более существенными являются интервалы до 360 (первый год нахождения ТВС в реакторе), до 1000 и до 1800 эфф. сут. при трехгодичной и пятигодичной кампаниях соответственно, использующихся в современных реакторах [2].

Рассмотренные соотношения урана и гадолиния в топливе приведены в табл. 2.

Таблица 2

Варианты соотношения урана и оксида гадолиния

Содержание Gd_2O_3 в твэгах, %	Обогащение твэлов, %	Содержание Gd_2O_3 в твэгах, %	Обогащение твэлов, %
5	2	7	2
5	2,25	7	2,25
5	2,5	7	2,5
5	2,75	7	2,75
5	3	7	3
5	3,25	7	3,25
5	3,5	7	3,5
5	3,75	7	3,75
5	4	7	4
6	2	8	2
6	2,25	8	2,25
6	2,5	8	2,5
6	2,75	8	2,75
6	3	8	3
6	3,25	8	3,25
6	3,5	8	3,5
6	3,75	8	3,75
6	4	8	4

Прогнозируемые изотопы представлены в табл. 1. В соответствие с номерами в табл. 1 к изотопам и k_∞ было применено one-hot кодирование, при этом k_∞ был присвоен номер 0.

ТВС разбивалась на 10 гексагональных колец пронумерованных от 0 до 9 в порядке удаления от периферии, было принято считать, что изотопный состав всех твэлов в одном кольце изменяется одинаковым образом. То же предположение было сделано для отдельно рассмотренных групп твэгов в

третьем и восьмом кольцах, получивших обозначения 10 и 11 соответственно. К данным обозначениям было применено one-hot кодирование.

Данные для обучения и тестирования нейросетевой модели являлись результатами заранее проведенных с помощью метода Монте-Карло в многоцелевом трехмерном коде с непрерывной энергией нейтронов Serpent [9]. Имеющиеся данные были разделены в отношении 90:10 на обучающие и тестовые. Тестовые данные были изъяты из набора данных, использовавшегося при обучении модели. Оставшиеся 90% данных при обучении каждый раз произвольным образом в отношении 80:20 делились на тренировочную и валидационную выборки соответственно.

Изначально данные представляли собой строку, содержащую данные о типе изотопа, положении твэла или твэга (т.е. обозначение кольца), обогащении, содержании гадолиния и содержание изотопа в топливном элементе в 13-ти временных точках от 0 до 3360 эфф. сут. Так как концентрации изотопов в топливе представляют собой довольно малые величины (порядок 10^{-2} - 10^{-21} в зависимости от нуклида), то в каждой строке они были приведены к интервалу [0; 1] по формуле:

$$X_{ij} = \frac{C_{ij}}{C_{j\max}} \quad i = 0, \dots, 12 \;\; j - \text{номер строки},$$

где X_{ij} – относительное содержание изотопа/относительное k_∞ j-й строки в i-й шаг времени, C_{ij} – исходное содержание изотопа j-й строки в i-й шаг времени, $C_{j\ \max}$ – максимальное значение содержания изотопа/ k_∞ в j-й строке. Всего для обучения использовалось 8544 строки, для тестирования было зарезервировано 1068 строк.

Архитектура сети

Для разработки нейронной сети в данной работе были использованы средства библиотек TensorFlow и Keras [10, 11].

В настоящей работе представлено развитие архитектуры нейросетевой модели предложенной в [5–8]. Схема разработанного нейросетевого алгоритма представлена на рис. 1.

На первый вход подается пара чисел (x, t), где x – относительное значение прогнозируемой величины в момент времени t, t – шаг времени, предшествующий времени желаемого прогноза, t = 0, …, 11. Эти значения обрабатываются сначала плотным слоев нейронов Dense, результаты вычислений которого передаются в рекуррентную нейронную сеть GRU. Выбор GRU обоснован тем, что она, так как и LSTM, способна моделировать долгую память, но в отличие от последней требует обучения меньшего числа параметров [12].

На второй вход подается массив чисел, состоящий из: one-hot кода для типа прогнозируемой величины, one-hot кода для обозначения положения топливного элемента, обогащение топлива – вещественное число и массовое содержание оксида гадолиния в твэгах – вещественное число.

Значения выхода рекуррентной нейронной сети и второго входа конкатенируются и проходят через два плотных слоя нейронов. После чего результат прогнозирования выводится посредством выходного плотного слоя.

Рис. 1. Схема разработанного нейросетевого алгоритма

Выходные данные, т.е. спрогнозированное значение, представлены парой чисел (x*, t*), где x* – относительное спрогнозированное значение запрашиваемой величины в момент времени t* = t + 1, t – шаг времени, следующий за предыдущим, t = 1, …, 12.

Во всех слоях, кроме последнего, используется сигмоидальная функция активации. В выходном слое используется линейная функция активации.

Для оценки качества работы нейронной сети использовались метрики:

- точность (Accuracy) – доля верно предсказанных значений;
- средний квадрат ошибки (MeanSquaredError);
- средний относительный модуль ошибки; (MeanAbsolutePercentageError).

В качестве функции потерь был выбран средний квадрат ошибки, так как нейронная сеть должна была предсказывать численные значения интересующей величины.

Для обучения нейронной сети применялся алгоритм оптимизации Adam с параметрами по умолчанию [11]. Размер партии для обучения был равен 57, число эпох обучения 50.

Исходя из формы входных и выходных данных, предполагающих прогнозирование по временным шагам, каждая строка обучающей и тестовой выборки, содержащая данные об относительных количествах прогнозируемых величин, был разделена на 12 пар (q, a), где q – данные о запрашиваемой величине в момент времени t, a – спрогнозированные для момента t + 1 относительные величины.

Результат обучения модели

Модель была оценена на наборе обучающих данных и наборе, изъятом из обучающей выборки. Результаты оценки приведены в табл. 3.

Таблица 3

Результат обучения модели

Метрика	Accuracy
Обучающая выборка	0,9993
Тестовая выборка	0,9999

По окончании обучения метрика точности имела довольно высокое значение. Качество обучения отслеживалось по графикам, иллюстрирующим результат работы нейросетевой модели при прогнозировании изменения величины в течении принятой топливной кампании. Оценивалось расхождение теоретического графика, построенного по результатам расчетов в Serpent, и экспериментального, построенного по результатам прогноза нейронной сети. Примеры приведены на рис. 2.

Рис. 2. Примеры графиков, иллюстрирующих результаты работы алгоритма для: а) k_∞; б) U235; в) Pu241; г) Gd155

Точки экспериментальных графиков получались следующим образом. Вначале начальное значение прогнозируемой величины наносилось на график. Затем по этим начальным значениям и данным о прогнозируемой величине нейросетью прогнозировалось значение величины на следующем шаге. После чего уже спрогнозированное значение подавалось на вход нейронной сети и так далее. На выходе получали спрогнозированные моделью значения для 12 шагов по времени, отражающие изменение величины в течение кампании. Точки, полученные в результате прогноза, также наносили на график.

Анализ результатов

Проанализировав результаты работы предлагаемого алгоритма, можно сделать следующие выводы.

Изменение в течение кампании ряда величин, например, k_∞ и U235, прогнозируется очень хорошо, расхождение с теоретическими значениями минимальны, данные прогноза актуальны в течение всей кампании.

В то же время с прогнозированием некоторых величин у модели возникают проблемы на отдельных участках кампании. Например, для большинства изотопов плутония, америция и кюрия, таким участком является начало кампании от 0 до 60, 210, 360 эфф. сут., а для Gd155 и Gd157 – продолжение кампании после 360 эфф. сут. Эти нарушения в работе алгоритма можно объяснить очень малыми долями накопления минорных актинидов в течение первого года эксплуатации ядерного топлива и практически полным выгоранием в это же время Gd155 и Gd157, т.е. их концентрации в топливе существенно уменьшаются. На этих участках значения величин близки к нулю, поэтому плохо прогнозируются используемым алгоритмом, что свидетельствует о необходимости его доработки. Однако он достаточно точно позволяет судить о накоплении минорных актинидов уже к концу первого года эксплуатации топлива и сохраняет эту тенденцию до конца кампании, что важно при планировании перегрузок и операций по переработке отработавшего ядерного топлива.

Заключение

Предложен и реализован алгоритм, основанный на нейронной сети, позволяющий прогнозировать изменение изотопного состава ядерного топлива. Последовательно применяя данный алгоритм для k_∞, различных гексагональных колец и изотопов можно спрогнозировать k_∞ и изотопный состав ТВС для данного обогащения твэлов и массового содержания оксида гадолиния в твэгах.

Так как большинство изменений концентраций различных нуклидов являются величинами, сильно коррелирующими между собой [1], то данную модель без существенной перестройки можно обучить прогнозированию практически любого минорного актинида, образующегося в процессе эксплуатации ядерного топлива.

Кроме того, за счет применения нейронной сети данный алгоритм является достаточно гибким и может с достаточно высокой точностью делать прогнозы для промежуточных значений обогащения и содержания оксида гадолиния, так как нейросети обладают высокой способностью к качественной аппроксимации данных.

Довольно высокая точность прогнозирования данного алгоритма, в частности величин k_∞ и U235, позволяет использовать его для проведения предварительных нейтронно-физических расчетов на выгорание.

К перспективам данной работы можно отнести повышение точности результатов работы алгоритма, требующее его доработки.

Список литературы

1. Тошинский Г.И. Беседы о ядерной энергетике. Физика реакторов и технологии модульных быстрых реакторов с теплоносителем свинец-висмут: для начинающих и не только. – М. : РГ-Пресс, 2020. – 480 с.

2. АЭС с реактором типа ВВЭР-1000. От физических основ эксплуатации до эволюции проекта / С.А. Андрушечко, А.М. Афров, Б.Ю. Васильев, В.Н. Генералов, К.Б. Косоуров, Ю.М. Семченков, В.Ф. Украинцев ; Москва : Логос, 2010. – 604 с. – ISBN 978-5-98704-496-4.

3. Карпеева А.Е., Колосовский В.Г., Пахомов Д.С., Скомороха А.Е., Тимошин И.С. Способ оптимизации термической стабильности уран-гадолиниевого топлива//Известия вузов. Ядерная энергетика. – 2021. – № 3. – С. 97–106. DOI: 10.26583/npe.2021.3.08.

4. Внуков Р.А., Колесов В.В., Жаворонкова И.А., Котов Я.А., Праманик М.Р. Влияние размещения выгорающего поглотителя на нейтронно-физические характеристики тепловыделяющей сборки ВВЭР-1200. Известия вузов. Ядерная энергетика. – 2021. – № 2. – С. 27–38. DOI: 10.26583/npe.2021.2.03.

5. Внуков Р.А., Шлапак Н.П. Использование рекуррентной нейронной сети для расчета изменения изотопного состава топлива реактора ВВЭР-1000. XVII Курчатовская молодежная научная школа. Сборник аннотаций. 2023. С. 98.

6. Болотникова А.А., Внуков Р.А., Шлапак Н.П. Прогнозирование изотопного состава твэгов в зависимости от начального обогащения топлива с применением нейросетевых алгоритмов // Сборник тезисов докладов. Будущее атомной энергетики – AtomFuture 2022. XVIII Международная научно-практическая конференция (Обнинск: 28–29 ноября 2022). 2022. С. 102–103.

7. Внуков Р.А., Шлапак Н.П. Анализ влияния гадолиниевого выгорающего поглотителя на изменение изотопного состава топлива с использованием нейронный сетей // Сборник тезисов докладов. Будущее атомной энергетики – AtomFuture 2022. XVIII Международная научно-практическая конференция (Обнинск: 28–29 ноября 2022). 2022. С. 113–114.

8. Болотникова А.А. Использование рекуррентной нейронной сети для прогнозирования изменения изотопного состава ядерного топлива // XXX Международная конференция студентов, аспирантов и молодых ученых по фундаментальным наукам «Ломоносов—2023». Секция «Физика». Сборник тезисов. 2023. – ISBN 978-5-8279-02-55-3. С. 78–79.

9. SERPENT – MCRPBCC. Электронный ресурс: https://serpent.vtt.fi (дата доступа 10.06.2023).

10. TensorFlow. Электронный ресурс: https://www.tensorflow.org/ (дата доступа 10.06.2023).

11. Keras API reference. Электронный ресурс: https://keras.io/api/ (дата доступа 10.06.2023)

12. Николенко С. Глубокое обучение / Николенко С., Кадурин А., Архангельская Е. – СПб.: Питер, 2018. – 480 с. – ISBN 978-5-496-02536-2.

Л.С. ЧЕРНЫШЕВ, И.М. АНТОНОВ
ООО «Матсофт», Москва
Math4soft@yandex.ru

СИСТЕМА ОПТИМАЛЬНОГО УПРАВЛЕНИЯ ТОРГОВЫМ ПРОЦЕССОМ С ИСПОЛЬЗОВАНИЕМ ИСКУССТВЕННОЙ НЕЙРОННОЙ СЕТИ И МЕТОДА ОПТИМИЗАЦИИ ДЕЛЬТА*

Решается задача построения оптимального управления (оптимального динамического ценообразования) торговым процессом на заданном временном горизонте управления с использованием искусственной нейронной сети и разработанного авторами метода оптимизации Дельта, для максимизации суммы целевой функции торгового процесса-функции прибыли по временным срезам заданного горизонта управления. Решение задачи проводится в 2 этапа: на первом этапе с помощью нейросетевой модели производится синтез цифрового двойника торгового процесса. На втором этапе для синтеза оптимального управления используется авторский метод оптимизации «Дельта», позволяющий определить набор значений управляющих параметров торгового процесса (набор цен) для всех временных срезов горизонта управления, максимизирующего его целевую функцию (прибыль) на заданном горизонте управления. Система тестируется на синтетическом (смоделированном) массиве данных.

Ключевые слова: *оптимальное управление; цифровой двойник; нейросетевая модель; искусственная нейронная сеть, целевая функция; параметры управления; техническая система; процесс; оптимизация, робастность управления.*

* Данная работа выполнена в рамках договора гранта от Фонда содействия инновациям 122ГС1ИИС12-D7/76682 от 09.06.2022.

Введение

В последние несколько лет розничная торговля в значительном объеме перешла на онлайн интернет-площадки – маркетплейсы. Многие мировые лидеры рынка электронной коммерции, включая Amazon, Walmart активно исследуют и используют алгоритмы динамического ценообразования для получения и поддержания конкурентного преимущества. Постоянное изменение цены – динамическое ценообразование, необходимо для подогрева интереса к товару. Является известным фактом, что товар с фиксированной ценой со временем теряет интерес для людей, делающих покупки на маркетплейсах, даже при продаже по «привлекательной» цене.

Очевидно, что сложности оптимальной корректировки цен в ответ на цены конкурентов, меняющиеся рыночные условия, взаимодействие между товарами собственного ассортимента продавца, отзывы потребителей, неполная информация о поведении потребителей и многие другие факторы, влияющие на спрос и выручку, огромны. Для решения этих сложностей появился большой поток исследований, в которых разрабатываются алгоритмы ценообразования и анализируется их эффективность. Особенно актуален вопрос: как продавец должен оценивать свои товары, чтобы оптимизировать прибыль, когда соотношение цены и спроса заранее неизвестно и, следовательно, должно быть изучено на основе накопления данных о продажах.

Подход динамического ценообразования, при котором решение покупателей о покупке зависит от множества предпочтительных атрибутов покупки, таких как цена продукта, качество продукта, послепродажное обслуживание, время доставки, репутация продавцов, которые входят параметрами в нейросетевую модель, рассчитывающую оптимальное ценообразование рассмотрен в работе [1]. Сотрудниками компании Walmart в 2018-2019 гг. проводились работы по внедрению аппарата активного обучения модели для построения динамического ценообразования на основе Томпсоновского сэмплирования [2], использующегося в важнейшей задаче планирования ресурсов – задаче о многоруких бандитах. Значимые результаты по внедрению подхода задачи «Многорукого бандита» и машинного обучения, основанного на алгоритме Томпсоновского сэмплирования для решения задачи динамического ценообразования, получены в работе [3]. Использование обучения с подкреплением и глубокого обучения с подкреплением для динамического ценообразования для продавцов маркетплейса рассмотрены в работе [4]. В работе [5] оценивается риск ценового «сговора» продавцов при автоматическом ценообразовании на один и тот же

товар. В работе [6] был разработан стохастический процесс на основе прогнозных значений от искусственной нейронной сети для определения спроса потребителей на электроэнергию, чтобы минимизировать среднюю цену на электроэнергию, которую платят пользователи. В работах [7, 8] алгоритмы машинного обучения используются в динамическом ценообразовании стоимости авиабилетов. В работах [9, 10] машинное обучение и оптимизация используются в динамическом ценообразовании стоимости сервисных услуг и стоимости придорожных парковочных мест. В работе [12] для динамического ценообразования используется двухэтапный подход – на первом этапе использующий глубокую нейронную сеть для прогнозирования в сочетании с технологией максимизации дохода с использованием дискретного исчерпывающего поиска (оптимизации) на втором этапе.

В данной работе торговый процесс рассматривается как объект, описываемый одним главным параметром состояния **Y** размерности m, определенном на множестве допустимых значений $D_{\mathrm{Y}} : D_{\mathrm{Y}} \subset \mathrm{R}^{\mathrm{m}}$, характеризующим вектор количества продаж в единицу временной дискретности за m последовательных единиц временной дискретности и одним главным параметром управления **U**, определенном на множестве допустимых значений $D_{\mathrm{U}} : D_{\mathrm{U}} \subset \mathrm{R}^{\mathrm{n}}$, характеризующим вектор средней цены в единицу временной дискретности за n последовательных единиц временной дискретности, где R^{m}, R^{n} – арифметические пространства размерности m и n соответственно. Учет влияния остальных, не поддающихся прямой оценке, параметров управления будет произведен за счет использования искусственной нейронной сети, моделирующей эволюцию торгового процесса на интервалах дискретности временной шкалы, используя только ряды исторических наблюдений за динамикой главного параметра управления U и динамикой основного параметра состояния торгового процесса Y.

Процедура построения оптимального управления (оптимального динамического ценообразования) торговым процессом на дискретных временных срезах $t \in \{1 \ldots T\}$ горизонта управления T будет проведена в 2 этапа. Первый этап – идентификация нейросетевой модели (ИНС модели) торгового процесса, состоящего из подэтапов обучения и валидации. При этом целевая функция торгового процесса (прибыль) определяется как $\mathbf{P}_{\boldsymbol{t}} = F(t, \mathbf{Y}_{\boldsymbol{t}}, \mathbf{U}_{\boldsymbol{t}})$, где $\mathbf{Y}_{\boldsymbol{t}}$ и $\mathbf{U}_{\boldsymbol{t}}$ – выборочные множества значений из областей допустимых значений для каждого среза $t \in \{1..T\}$ горизонта управления T соответственно параметра состояния Y(t) и параметра управления U(t). На втором этапе находится оптимальное управление (оптимальное динамическое ценообразование) торговым процессом при максимизации целевой

функции $\mathbf{P}_{\boldsymbol{t}}$, в виде набора управляющих параметров (цены) $< U_t >_{опт}$, состоящего из определенных значений U_t, выбранных из области допустимых значений параметра управления U(t) для каждого среза $t \in \{1..T\}$ горизонта управления T.

$$< U_t >_{\text{опт}} = \underset{U_t}{\text{Argmax}}\left(\sum_{t=0}^{T} P(t, \boldsymbol{U}_t, \boldsymbol{Y}_t)\right). \quad (1)$$

1. Постановка задачи идентификации ИНС модели торгового процесса

Идентификация есть процесс построения математической модели объекта, адекватной объекту с точностью до заданного критерия. Пусть L+F – длина ретроспективных временных рядов параметров торгового процесса (далее объект управления или объект), имеющихся в нашем распоряжении – состоящих из ряда значений параметра состояния y(t) объекта и параметра управления U(t) объектом, наблюдаемых за определенный период времени в прошлом. Разделим эти ряды на 2 отрезка: больший отрезок этих рядов длинной L мы будем использовать для обучения ИНС, меньший, длинной F, для валидации. Пусть t∈ $\{\mathbf{1}..\boldsymbol{L}\}$ – временной индекс итерации работы ИНС в первой стадии идентификации модели – режиме обучения ИНС, на каждом из которых происходит уточнение результата $\hat{\boldsymbol{y}}(\boldsymbol{t})$ – аппроксимации случайного процесса динамики во времени параметра состояния объекта управления $\boldsymbol{y}(\boldsymbol{t})$ с помощью ИНС. На каждом шаге обучения t результат аппроксимации имеет ошибку в виде случайного процесса $\boldsymbol{\varepsilon}(\boldsymbol{t})$ (рис. 1).

Рис. 1. Схема идентификации модели ИНС

На каждом временном шаге обучения t результат аппроксимации динамики параметра состояния объекта (результат работы прогнозирующей ИНС модели) может быть представлен в виде функции $g(\boldsymbol{\varphi}(t), \boldsymbol{\theta}(\boldsymbol{t}))$, где в $\boldsymbol{\varphi}(t)$

входят в виде параметров экзогенные переменные – ретроспективный ряд длиной K_u управляющих параметров объекта управления $\boldsymbol{u}(t)$ и ряд длинной K_y рассчитанных на прошлых *t* значений оценок $\hat{y}(t)$ – аппроксимации случайного процесса изменения параметра состояния объекта управления $y(t)$, подающихся на входные нейроны ИНС, и внутренних параметров ИНС – матрицы синаптических коэффициентов $\boldsymbol{\theta}$, прошедших корректировки на предыдущих итерациях работы ИНС. Описание параметров состояния объекта управления с помощью нейросетевой модели может быть представлено в следующем виде [13]:

$$y(t) = g(\boldsymbol{\varphi}(t), \boldsymbol{\theta}(\boldsymbol{t})) + \varepsilon(t), \tag{2}$$

где $\varepsilon(t)$ – последовательность независимых случайных величин, характеризующих ошибку идентификации ИНС модели объекта управления, тогда оценка параметров состояния с помощью прогнозирующей ИНС модели запишется как:

$$\hat{y}(t|\boldsymbol{\theta}) = g\big(\boldsymbol{\varphi}(t), \boldsymbol{\theta}(\boldsymbol{t})\big), \tag{3}$$

$$\boldsymbol{\varphi}(t) = \left[\hat{y}_{t-1} \dots \hat{y}_{t-K_y}, U_t, \dots, U_{t-K_u+1}\right] \tag{4}$$

Наиболее удобной для обучения прогнозирующей модели $g(\boldsymbol{\varphi}(t), \boldsymbol{\theta}(\boldsymbol{t}))$ является конструкция полносвязной нейронной сети прямого распространения с одним входным слоем с числом нейронов K_y+K_u, причем на его первые K_y нейронов подаются на шаг более ранние K_y прогнозов параметров состояния объекта $\left[\hat{y}_{t-1} \dots \hat{y}_{t-K_y}\right]$, а на последующие K_u нейронов подаются K_u значений управляющего параметра в предыдущие моменты времени, начиная с текущего: $[U_t, \dots, U_{t-K_u+1}]$, при этом функция активации входного слоя равна единице, один скрытый слой имеет G нейронов и выходной слой имеет всего один нейрон, с функциями активации вида гиперболический тангенс для скрытого и выходного слоев. Тогда функция прогноза имеет следующее математическое представление:

$$\hat{y}(t|\boldsymbol{\varphi}, w, W) = f\left(\sum_{j=1}^{G} W_j\, f\left(\sum_{i=1}^{K_y} w_{ji}\, \hat{y}_{t-i} + \sum_{i=0}^{K_u-1} w_{ji}\, U_{t-i} + w_{j0}\right) + W_0\right), \tag{5}$$

где f(x) = tanh(x) – активационная функция нейронов скрытого и выходного слоя; K_y+K_u – число входов ИНС; G – число нейронов в скрытом слое; вектор параметров $\hat{y}$ предыдущих прогнозных оценок параметров состояния

объекта, текущее и предыдущие значения параметров управления **U**, весовые коэффициенты (w_{ji}, W_j) и нейронные смещения (w_{j0}, W_0) соответственно скрытого и выходного слоев.

Методом прямого распространения ИНС производится расчет прогнозного значения $\hat{y}(t)$, затем методом обратного распространения ошибки с использованием градиентного метода наискорейшего спуска [14, 15] корректируются весовые коэффициенты и смещения в (5). Причем при достижении t = t_L, где L – длина выборки обучения, начинается новая эпоха обучения и значения индексов снова начинаются с t = t_{K_y}. Вторая часть идентификации – валидация, проводится согласно [16-18] на отрезке ретроспективных рядов длинной F параметров состояния и параметров управления Объекта, которые не участвовали в процедуре обучения. Критерием успешности идентификации служат значения MSE – средней суммы квадрата разности значений нейросетевой аппроксимации на участке обучения: t∈ $\{\boldsymbol{K}..\boldsymbol{L}\}$ и значений исходного обучающего ряда параметров состояния Объекта для всей длины отрезка обучения, и аналогичной ошибки рассчитанной по значениям прогноза ИНС и исходных валидационных рядов для t∈ $\{\boldsymbol{L}..\boldsymbol{L}+\boldsymbol{F}\}$**.** А также на базе RMSE – отношения значений MSE на текущей эпохе обучения к значению MSE на нулевой эпохе обучения.

$$MSE_Educ = \frac{\sum_{\mathrm{K}}^{\mathrm{L}}(\hat{y}_{\mathrm{t}} - y_{\mathrm{t}})^2}{(\mathrm{L}-\mathrm{K})}, \quad MSE_Valid = \frac{\sum_{\mathrm{L}}^{\mathrm{L+F}}(\hat{y}_{\mathrm{t}} - y_{\mathrm{t}})^2}{(\mathrm{F})}, \tag{6}$$

Модель считается идентифицированной, если ошибка валидации и ошибки обучения, рассчитанные согласно (6) оказываются меньше установленных порогов.

Общая формула прогнозной модели имеет вид [7]:

$$\begin{aligned} Y_{\mathrm{t}}(t, U_{\mathrm{t}}, U_{\mathrm{t}-1}, \dots U_1, Y_{\mathrm{t}-1}, \dots Y_1) = \\ = \mathrm{f}\Bigg[\sum_{j=0}^{G}\Bigg[\mathrm{f}\Bigg[\sum_{i=0}^{Kx-t}(bx_{i,j}\cdot dy(L-K+t+i)) \\ + \sum_{i=0}^{Ku-t-1}(bu_{i,j}\cdot dp(L-K+t+i+1)) + bb_j \\ + \sum_{i=1}^{t-1}\left(bx_{Kx-t+i+1,j}\cdot Y_{\mathrm{i}}\right) + \sum_{i=1}^{t-1}(bu_{Ku-t+i,j}\cdot U_{\mathrm{i}}) \\ + bu_{Ku,j}\cdot U_{\mathrm{t}}\Bigg]\cdot b2_j\Bigg] + bb2\Bigg], \end{aligned} \tag{7}$$

где Y_i – значения параметров состояния, рассчитанных по (7) для предыдущих текущему временных срезов: $i \in \{0...t\text{-}1\}$. U_t – наборы варьируемых (моделируемых) на этапе синтеза управления значений управляющих параметров, соответствующих $t \in \{1...T\}$, имеющих заданную дискретность и ограничение на значения $U_{min_t} \leq U_t \leq U_{max_t}$; $bx, bu, b2$ – весовые коэффициенты и нейронные смещения скрытого и $bb, bb2$ – выходного слоев соответственно.

2. Синтез оптимального управления методом Дельта

Решение задачи оптимального управления (1) с помощью модифицированного алгоритма Томпсоновского сэмплирования предложено в [16]. Альтернативный метод оптимизации, метод Дельта, изложен в [19], основан на делении диапазона допустимых значений управляющего параметра для всех $t \in \{1...T\}$ на одинаковое число отрезков Nu. Пусть

$$U_{min_t} = U_{min} = E\big(U(t)\big) - 3*\sigma, \quad U_{max_t} = U_{max} = E\big(U(t)\big) + 3*\sigma,$$

где $E\big(U(t)\big)$ – выборочное среднее и σ – стандартное среднеквадратическое отклонение для значений имеющегося временного ряда модельных или фактических, измеренных ранее значений управляющего параметра $U(t)$. Тогда для каждого $t \in \{1...T\}$ строят выборочное множество $\mathbf{U}_t$ размером Nu: $\mathbf{U}_t = \{U_{i.t}\}$, $i \in \{0..\text{Nu-1}\}$, $U_{i.t} = U_{min_t} + i * \frac{U_{max_t} - U_{min_t}}{\text{Nu}}$. Затем для каждого t по (2) рассчитывают $Y_{i.t}$, формирующих множество $\mathbf{Y}_t$, размерность которого Z_t растет с ростом t как Nu^t (рис. 2).

Для торгового процесса целевая функция – функция прибыли определяется как (8):

$$P_{k.t} = Y_{i.t} * (U_{j.t} - \text{NetCost}), \tag{8}$$

где NetCost – себестоимость товара.

При этом из (8) следует, что

$$\text{Dim}(\mathbf{P}_t)\ (\text{размерность вектора}(\mathbf{P}_t)) = \text{Dim}(\mathbf{Y}_t) \cdot \text{Dim}(\mathbf{U}_t),$$

однако так как согласно (8) в расчет $P_{k.t}$, как и в $Y_{i.t}$, согласно (7) входит один и тот же параметр $U_{j.t}$, то $k=i$, соответственно

$$\text{Dim}(\mathbf{P}_t) = \text{Dim}(\mathbf{Y}_t) = \text{Nu}^t.$$

Тогда если рассматривать уникальные траектории $< P_{i.t} >$, проходящие, как показано на рисунке 2, через одно выборочное значение для каждого временного среза $t \in \{1...T\}$, в которых хотя бы одно значение не встреча-

ется в других построенных траекториях, то таких траекторий можно построить максимально Nu^T штук (по числу выборочных элементов последнего временного среза t=T). Для решения задачи оптимального управления (1) в первом приближении необходимо сравнить суммы всех элементов (узловых точек) уникальных траекторий $< \mathrm{P}_{i.\mathrm{t}} >$, где $\mathrm{i}\in\{0..\mathrm{Nu}^T\}$. Т.е определить $S_i = \sum_{\mathrm{t}=0}^{\mathrm{T}} \mathrm{P}_{i.\mathrm{t}}$, $\mathrm{i}\in\{0..\mathrm{Nu}^T\}$. Пусть траектория с индексом z1: $S_{z1} = \max(\mathrm{S})$, тогда набор $< U_{z1.\mathrm{t}} >$ локально оптимизирует целевую функцию и является решением задачи оптимального управляения в первом приближении. Вторая итерация проводится так: находится индекс z2 второго максимума: $S_{z2} = \max(\mathrm{S} \cap S_{z1})$; для всех t вычисляются $U_{\mathrm{c,t}} = \frac{U_{z1,t}+U_{z2,t}}{2}$; далее если $\left|U_{\mathrm{c,t}} - U_{max_t}\right| > \left|U_{\mathrm{c},t} - U_{min_t}\right|$, то новое значение $U_{max_t}{}^1 = U_{max_t}{}^0 - \frac{(U_{max_t}{}^0 - U_{min_t}{}^0)}{10}$, иначе

$$U_{min_t}{}^1 = U_{min_t}{}^0 + \frac{(U_{max_t}{}^0 - U_{min_t}{}^0)}{10},$$

где верхние индексы означают номер итерации оптимизации; $U_{max_t}{}^0, U_{min_t}{}^0$. После сдвига границ новая дискретность

$$\Delta_t{}^1 = \left(U_{max_t}{}^1 - U_{min_t}{}^1\right)/Nu. \text{ Так как } \Delta_t{}^1 < \Delta_t{}^0,$$

то можно добиться более точного определения локально-оптимального набора $< U_t >_{\text{опт}}$. Итерации могут быть остановлены, например, если итерация не привела к росту суммы целевой функции.

Рис. 2. Схема иерархии выборочных множеств параметра состояния процесса $\boldsymbol{Y_{i.t}}$ с ростом индекса временного среза горизонта управления $\mathrm{t}\in\{1...T\}$

3. Модель синтетических данных

Для тестирования метода оптимального управления на модельных данных использовались зависимости параметра состояния от значений параметра управления вида:

$$U_i = \frac{i}{L - 20 \cdot c} \cdot 16 + 0.04 \cdot rand(-99{,}99), \tag{9}$$

при $i \leq (\mathrm{L} - 20 \cdot \mathrm{c})$, где c – параметр рассматриваемой дискретности ряда, в нашем случае c = 7.

$$U_i = 16 - \frac{i - L + 20 \cdot c}{F \cdot 0.5 + 10 \cdot c} \cdot 4 + 0.04 \cdot rand(-99{,}99), \tag{10}$$

при $(\mathrm{L} - 20 \cdot \mathrm{c}) < i < L + F$.

Далее рассчитывалось среднее: M(U)= np.mean(U) и стандартное отклонение ряда U: σ(U) = np.std(U), затем значения $\mathrm{U_i}$ пересчитывались как:

$$U_i = U_i + 30 \cdot \sigma(U), \;\; i = \{1 \ldots L + F\}. \tag{11}$$

Параметр состояния торгового процесса Y_i задавался как (2.3.21):

$$\begin{aligned} Y_\mathrm{i} = 2150 + \sin\left(\frac{\mathrm{i}+1}{3}\right) \cdot 0.5 + \sin\left(\frac{\mathrm{i}+1}{15}\right) \cdot 5 + \mathrm{int}\left(\frac{\mathrm{i}}{\mathrm{L}}\right) \cdot (\mathrm{i} - \mathrm{L}) \cdot 0.1 + 0.5 \\ + 0.3 \cdot U_\mathrm{i} - \left(\frac{2}{3}\right) \cdot (U_\mathrm{i})^3 / \mathrm{abs}((U_\mathrm{i})^{1.39}) + 0.02 \cdot \mathrm{rand}(1{,}99) \\ + 5 \end{aligned} \tag{12}$$

В результате вид модели показан на рис. 3.

Рис. 3. Вид модели № 1. Сверху – продажи, снизу – цены

Для повышения чувствительности цифрового двойника к управлению предложен специальный метод. Нейросети нужно сделать дополнительное «напоминание» о том, какие значения параметра состояния соответствуют максимальному и минимальному значениям параметра управления. Данный подход авторы назвали «метод шпилек». После 200 итераций обучения ИНС модель выглядела следующим образом (рис. 4).

Рис. 4. ИНС модель после 200 итераций обучения RMSE = 0.029

Результат работы метода оптимизации ДЕЛЬТА показан на рис. 5.

Основное поле рис. 5 (кроме его крайне-правой части) занимает ход динамики параметров состояния торгового процесса Y_i (количество продаж) и параметра управления процесса U_i (цены),сгенерированных согласно задающих синтетический массив формул (9)–(11), а так же ход динамики параметра состояния YY_i (количество продаж) цифрового двойника рассматриваемого процесса, построенного с помощью идентифицированной ИНС модели по (7). Особый интерес на рис. 5 представляет его правая часть, представляющая отрезок времени горизонта управления. На этом отрезке, кроме указанной выше динамики параметров $\mathrm{Y}_i, U_i, \mathrm{YY}_i$ отражены динамики параметров состояния $\mathrm{Y0}_i, \mathrm{YZ}_i, \mathrm{Y}G\mathrm{M}_i, \mathrm{YF}or\mathrm{m}_i$, представляющие из себя результат подстановки в генерирующий исходный массив формулу (12) следующих управляющих параметров: соответственно для $\mathrm{Y0}_i$: подставлялось $\mathrm{U}_{\min.i}$ – минимально возможное управление (цена), использованное в методе оптимизации Дельта для $\forall \mathrm{t} \in \{1...T\}$; YZ_i: в (12) подставлялось $\mathrm{U}_{max,i}$ – максимально возможное управление (цена), использованное в методе Дельта для $\forall \mathrm{t} \in \{1 \ldots T\}$; YGM_i – подстановкой в (12) $\mathrm{U}_{const,i}$ для

$\forall$ t∈{1...T} – неизменное управление в виде фиксированной цены , равной последнему известному значению временного ряда U_i; для расчета $\mathrm{YF}orm_i$ в (12) подставлялось $\mathrm{U}_{\mathrm{formula},i}$ – управление (цена) являющейся продолжением формул (9)-(11). А так же основной результат – $\mathrm{Y1}_i$ – динамики числа продаж, полученных подстановкой в (12) рассчитанного по методу Дельта оптимального управления (оптимальных цен) $\mathrm{U}_{opt,i}$ для $\forall$ t∈{1..T}.

Рис. 5. Пример оптимизации методом Дельта результатов нейросетевого прогноза. Различные варианты динамик продаж рассчитаны по синтезирующей массив формуле (12) подстановкой основных типов управлений: $\mathrm{U}_{\mathrm{min}.i}$, $\mathrm{U}_{max,i}$, $\mathrm{U}_{const,i}$, $\mathrm{U}_{\mathrm{formula},i}$, $\mathrm{U}_{opt,i}$.

Полученные качественные показатели: плановая себестоимость Seb=20.47; начальная цена 52.66; Оптимальный ценовой алгоритм:

$$\mathrm{U}_{opt,i} =$$
$$= [49.59\ \ 47.92\ \ 44.39\ \ 47.92\ \ 51.46\ \ 47.92\ \ 46.26\ \ 42.73\ \ 46.26\ \ 49.79].$$

Мерой эффективности построенного оптимального управления (оптимальный ценового алгоритма) на конкретном временном срезе является параметр $\mathrm{RProf}_\mathrm{t}$:

$$RProf_t = \sum_{i=1}^{t} Popt_i \,/\, \sum_{i=1}^{t} Pzero_i, \qquad (13)$$

для t∈{1..T}, где $Popt_\mathrm{t}$ получен из (8) подстановкой $\mathrm{Y1}_i$ и $\mathrm{U}_{opt,i}$; $Pzero_i$ – получен из(8) подстановкой $\mathrm{U}_{const,t}$и YGM_t.

Для указанной на рис. 5 оптимизации получены следующие результаты $\mathrm{RProf}_\mathrm{t}$= [1.09 1.1 1.1 1.1 1.09 1.09 1.09 1.09 1.1 1. 9]. Т.е. по сумме прибыли,

полученной нарастающим итогом для каждого временного среза имеем почти 10 % превышение по сравнению с отсутствием управления (постоянная цена). Модель № 2 имела вид, показанный на рис. 6 и 7.

Рис. 6. Вид динамики управляющего параметра и параметра состояния торгового процесса модели № 2

Рис. 7. Оптимизация по ИНС по модели № 2

$RProf_t$ = [1.12 1.17 1.15 1.15 1.16 1.17 1.18 1.19 1.2 1.2], т.е. по сумме прибыли, полученной нарастающим итогом для каждого временного среза имеем

почти от 12 до 20 % превышение по сравнению с отсутствием управления (постоянная цена). Тестирование Модели № 3 представлено на рис. 8 и 9.

Рис. 8. Вид динамики управляющего параметра и параметра состояния торгового процесса модели № 3

Рис. 9. Оптимизация по ИНС по модели № 3

$RProf_t$ = [1.05 1.07 1.1 1.12 1.1 1.1 1.11 1.12 1.13 1.13], т.е. по сумме прибыли, полученной нарастающим итогом для каждого временного среза,

имеем от 5 до 13 % превышение по сравнению с отсутствием управления (постоянная цена).

Заключение

В работе на синтетическом массиве данных, сгенерированным по аналогии со статистикой продаж товара на маркетплейсе, апробирован двухэтапный подход к построению оптимального набора значений управляющих параметров (цены) торгового процесса, на который кроме основного управляющего параметра влияет большое количество случайных факторов, количественно оценить которые напрямую невозможно. Построенный набор значений позволяет оптимизировать целевую функцию процесса (в нашем случае- максимизировать сумму прибыли) на установленном временном горизонте (горизонт управления). Решение задачи проводится в 2 этапа – на первом производится синтез цифрового двойника объекта управления с помощью нейросетевой модели. На втором этапе для синтеза оптимального управления используется авторский метод оптимизации «Дельта». Тестирование эффективности построенных оптимальных управлений производилось по суммам целевых функций для трех типов синтетически заданных массивов, моделирующих процессы реализации товаров на маркетплейсе. Для каждого из синтетических массивов построенное указанным методом оптимальное управление – набор оптимальных цен на горизонте управления, составляющем около 10 % от длины обучающих рядов – подставлялись в формулы генерации синтетических массивов для прямого расчета параметров состояния торгового процесса- количества продаж и затем –расчета значений целевых функций – прибыли для каждого временного среза горизонта управления. В качестве оценки эффективности выступало отношение сумм прибылей, полученное нарастающим итогом по срезам горизонта управления с использованием оптимального управления (оптимальных цен) методом его подстановки в формулы генерации синтетических массивов, рассчитанного по нейросетевому цифровому двойнику торгового процесса к суммам прибылей по тем же временным срезам, но рассчитанным при подстановке в формулы генерации синтетических массивов пассивного управления (цена = const). Значения эффективности по отношениям прибылей колеблются от 9 до 20 % для различных типов синтезированных массивов и различных временных срезов горизонта управления.

Список литературы

1. Ghose T.K., Tran T.T. A Dynamic Pricing Approach in E-Commerce Based on Multiple Purchase Attributes // In: Farzindar, A., Kešelj, V. (eds) Advances in Artificial Intelligence. Canadian AI 2010. Lecture Notes in Computer Science. 2010. V. 6085. Springer, Berlin, Heidelberg.

2. Ganti R., Sustik M., Tran Q., Seaman B. Thompson sampling for dynamic pricing // arXiv:1802.03050. 2018.

3. Ferreira K.J., Simchi-Levi D., Wang H. Online Network Revenue Management Using Thompson Sampling // SSRN Electronic Journal. 2015.

4. Hirano M., Matsushima H., Izumi K., Mukai T. Simulation of Unintentional Collusion Caused by Auto Pricing in Supply Chain Markets. 2020. https://doi.org/10.13140/RG.2.2.11305.21607.

5. Castiglioni M., Marchesi A., Gatti N. Be a Leader or Become a Follower: The Strategy to Commit to with Multiple Leaders // In: IJCAI International Joint Conference on Artificial Intelligence. International Joint Conferences on Artificial Intelligence. 2019. P. 123–129.

6. Majumdar A., Gurpinder S., Swarnkar A. et al. Dynamic Electricity Pricing by Modified Levenberg-Marquardt Backpropagation (LMBP) Algorithm // In: Tripathi A., Soni A., Shrivastava A., Swarnkar A., Sahariya J. (eds) Intelligent Computing Techniques for Smart Energy Systems. Lecture Notes in Electrical Engineering. V. 862. Springer, Singapore. P. 591–608.

7. Shihab S.A.M. DeepARM: An Airline Revenue Management System for Dynamic Pricing and Seat Inventory Control using Deep Reinforcement Learning // Thesis for: PhD, Project: Airline Revenue Management. 2020.

8. Kumar R., Boluki Sh., Isler K., Rauch J., Walczak D. Machine Learning based Framework for Robust Price-Sensitivity Estimation with Application to Airline Pricing // arXiv:2205.01875. 2022.

9. Jia H. Adaptive Optimization and Learning for Service Systems // A dissertation submitted in partial fulfillment of the requirements for the degree of Doctor of Philosophy (Industrial and Operations Engineering) in the University of Michigan. 2022.

10. Zhao Cong, Yi-Fan, ZhuXing-Hua, LiYu-Chuan Du A Real-time Prediction Method of Curbside Parking Occupancy Incorporating Dynamic Management Policies // Journal of Transportation Systems Engineering & Information Technology. 2020. V. 20. No. 5. P. 107–113.

11. Pasechnyuk D.A, Dvurechensky P., Omelchenko S., Gasnikov A. Stochastic optimization for dynamic pricing // arXiv:2106.14090v1. 2021.

12. Shukla N., Kolbeinsson A., Otwell K., Marla L., Yellepeddi K. Dynamic Pricing for Airline Ancillaries with Customer Context // In Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining (KDD '19). Association for Computing Machinery, New York, NY, USA. P. 2174–2182.

13. Методы робастного, нейро-нечеткого и адаптивного управления / Под ред. Егупова Н.Д. М.: МГТУ им. Баумана. 2002. 744 с.

14. Нестационарные системы автоматического управления: анализ, синтез и оптимизация / Под ред. Пупкова К.А., Егупова Н.Д. М.: МГТУ им. Баумана. 2007. 632 с.

15. Хайкин С. Нейронные сети: полный курс. М.: Издательский дом «Вильямс». 2006. 1104 с.

16. Чернышев Л.С. Способ оптимального управления технической системой или процессом с использованием нейросетевой модели и алгоритма Томпсоновского сэмплирования // Труды 20 национальной конференции по искусственному интеллекту КИИ-2022. М.: МЭИ. Т. 2. С. 427–440.

17. Чернышев Л.С. Способ управления технической системой или процессом с помощью искусственной нейронной сети, оптимизирующий целевую функцию // Тезисы докладов II Научно-практической конференции «Физико-технические интеллектуальные системы». 2023.

18. Чернышев Л.С. Идентификация нейросетевой модели технической системы или процесса с целью синтеза оптимального управления // Технологии электромагнитной совместимости. 2023. №2 (85). С.74–79.

19. Чернышев Л.С., Антонов И.М. Метод оптимизации «Дельта» для нахождения оптимального управления технической системой или процессом с использованием нейросетевого двойника и его апробация на синтетическом массиве данных // XXVI Международная конференция по мягким вычислениям и измерениям (SCM-2023). Сборник докладов. Санкт-Петербург. СПб.: СПбГЭТУ «ЛЭТИ». 2023. С. 136–141.

20. Воронов А.А. Теория автоматического управления. Ч. 1. М.: Высшая школа. 1986.

К.А. НОВОЖИЛОВ, С.П. КОЖЕВНИКОВ, Д.С. КОЗЛОВ, Д.А. КОМЫШЕВ, В.Г. СЕРГЕЕВ
Удмуртский государственный университет, Ижевск
dlisov41@gmail.com

ДИАГНОСТИКА БОЛЕЗНИ ПАРКИНСОНА С ИСПОЛЬЗОВАНИЕМ МЕТОДОВ ГЛУБОКОГО МАШИННОГО ОБУЧЕНИЯ ПО ДАННЫМ ЭЛЕКТРОЭНЦЕФАЛОГРАФИИ

В данной работе исследуется использование сверточных нейронных сетей для определения болезни Паркинсона на основе данных электроэнцефалографии (ЭЭГ). В исследовании приняли участие 47 человек. Запись ЭЭГ производилась по 21 отведению, к которым был применен анализ когерентности. Модель показала усредненную достоверность 72-79% для разных частотных диапазонов. Максимальная достоверность в тета-диапазоне, что может быть вызвано синхронизацией тремора с тета-ритмом контралатерального полушария головного мозга.

Ключевые слова: *болезнь Паркинсона, когерентность, машинное обучение, электроэнцефалография.*

Введение

Актуальной проблемой современной диагностики БП является возможность распознавания болезни на доклинической стадии, когда моторные нарушения отсутствуют. Предполагается, что на доклинической стадии могут проявляться не моторные признаки паркинсонизма (например, электрофизиологические, генетические и биохимические) на основе которых возможно оценить риск дальнейшего развития болезни.

Информативным, но весьма дорогим методом диагностики (измерение плотности нейронов) является позитрон-эмиссионная томография (ПЭТ). В следствие своей дороговизны, ПЭТ невозможно применить на практике скрининга широкой группы населения с целью доклинического диагностирования БП.

Электроэнцефалографическое исследование является недорогим методом, применимым для поиска признаков БП. Для этого, необходимо анализировать признаки ЭЭГ на диагностированных, но еще не леченых пациентах с БП. Для первой стадии свойственно одностороннее проявление нарушения движений левых или правых конечностей.

Некоторые признаки ранней стадии БП были рассмотрены в работе посвящённой изменению показателей спектрального анализа ЭЭГ при деменции с тельцами Леви [1]. Спектральный Фурье-анализ показал, что для пациентов с БП без деменции характерно снижение частоты альфа ритма в диапазоне 8–12 Гц, а также перераспределение мощности магнитной энцефалограммы МЭГ в частотных диапазонах дельта (0,5–4 Гц), тэта (4–8 Гц), низкого альфа (8–10 Гц), высокого альфа (10–13 Гц), бета (13–30 Гц) и гамма (30–48 Гц) [1]. В статье [2] показано, что одним из признаков может быть повышение энтропии сигнала. Это соотносится с рассогласованием работы разных структур мозга. Как правило, частотно-временной анализ ЭЭГ у пациентов с БП базируется на вейвлет преобразовании Морле [3]. В работе [4] была выявлена нестабильность в альфа (8–12 Гц) и бета (12-25 Гц) диапазонах частот вейвлет-спектрограмм ЭЭГ у пациентов на ранней стадии БП. Такая дезинтеграция проявляющейся на разных системных уровнях, по мнению некоторых авторов, характерна для ранней стадии БП [5].

Ранее был предложен подход, позволяющий оценить дезорганизацию ЭЭГ. Он основан на выделении экстремумов вейвлет-спектрограмм и последующем анализе частотно-временного распределения по различным отведениям мозга. В работах был предложен метод количественной оценки признаков БП на основе данных пациентов в ранней стадии и контрольных волонтеров. Алгоритм был основан на анализе локальных экстремумов частотно-временных гистограмм экстремумов вейвлет спектрограмм [6].

Было обнаружено, что тремор, измеренный акселерометром, синхронизован с тэта ритмом контралатерального полушария головного мозга. В итоге были предложены количественные оценки асимметрии тремора и межполушарной асимметрии ЭЭГ, а также дезорганизации динамики ЭЭГ.

Постановка задачи

Вышеупомянутые работы имеют несколько ограничений, во-первых, предложенные методики композиции количественных признаков предусматривают нормировку. К примеру, амплитуда тэта ритма нормируется на амплитуду альфа ритма. Аналогично нормировка происходит со среднеквадратичным отклонением коэффициентов корреляций и с амплитудами тремора конечностей. Подобная нормировка позволяет перевести объект в евклидово пространство одинаковых размерностей, но при этом может теряться общая распознавательная способность.

Во-вторых, предполагается наличие абстрактного испытуемого с априори известными значениями признаков. Это позволяет ввести метрику бли-

зости, по которой возможно ранжирование испытуемых. Однако, под вопросом остается оправданность и достоверность критериев выбора абстрактного испытуемого.

Одним из возможных способов избежать обозначенных недостатков является применение новых математических методов анализа с использованием алгоритмов искусственного интеллекта и машинного обучения. «Обучение» нейронной сети на основе сравнения данных ЭЭГ активности здоровых и больных испытуемых при методе максимизации правдоподобия позволяет избежать потребности в абстрактном испытуемом и не требует нормировки. Подобные подходы могут рассматриваться в качестве перспективного инструмента, облегчающего и повышающего точность диагностики на ранних стадиях болезни, а также, возможно, позволят выделить группы риска при исследовании клинически здоровых людей.

Для распознавания БП было предложено рассматривать задачу, как бинарный классификатор в пространстве матриц когерентности. В качестве базовой оценки было предложено использовать показатель достоверности случайной классификации равный 64 %. Исходя из этого для доказательства успешности предложенной модели усредненный показатель достоверности при *k-fold* валидации должен быть выше 70 %.

Метод

Применение методов ЭЭГ диагностики позволяет оценить нейрофункциональные паттерны многих неврологических заболеваний, определить степень нарушения мозговых функций и подобрать эффективное лечение. Однако применительно к БП использование «рутинной» ЭЭГ и классических методов амплитудно-частотного анализа, на основе преобразования Фурье, эффективно только в 30–40 % случаев, что ограничивает возможности ее применения.

Для повышения точности нашего метода были решены следующие задачи:

1. Разработан новый протокол ЭЭГ-исследования.
2. В качестве параметра ЭЭГ был выла выбрана когерентность.
3. Применён новый подход к математическому анализу данных ЭЭГ с использованием методов искусственного интеллекта.

Что касается первой задачи, поскольку развитие гиперкинезов сопровождается нарушением контроля и координации двигательной активности, поиск их нейрофизиологических коррелятов, помимо записи «рутинной» ЭЭГ требует включения в схему исследования дополнительных функциональных проб, направленных на выполнение сложно-координированной

двигательной деятельности. Необходимость актуализации сопряженных с затруднениями (дефицитных) функций может активировать скрытые патологические процессы. Кроме того, это может приводить к активации компенсаторных процессов, позволяющих преодолеть функциональный дефицит, что также может находить отображение в изменении различных параметров биоэлектрической активности.

В качестве одного из параметров, отражающих процессы подготовки и выполнения различных двигательных программ можно рассматривать динамику пространственной синхронизации осцилляторных процессов в различных областях коры головного мозга при выполнении различных функций. Пространственная синхронизация биопотенциалов в определенных частотных диапазонах и когерентность этих процессов имеет важное значение для проведения возбуждения между различными отделами коры больших полушарий, а также между корой и подкорковыми структурами. Эти процессы составляют основы кортико-таламо-кортикальных взаимодействий, которые играют ключевую роль в формировании двигательных программ сложных целенаправленных движений, а также механизмах контроля двигательной активности. Функционально значимые этапы произвольной двигательной деятельности сопровождаются возникновением в ряде областей коры и подкорковых структур мозга явлений локальной синхронизации. Эти явления коррелируют во времени с моментом активации внимания (сигнал к действию или раздражитель), а также с реализацией произвольного движения. Характер процессов синхронизации может изменяться при нарушении функций отдельных структур головного мозга, принимающих участие в организации произвольного движения. Данные нарушения должны находить отражение в изменении показателей когерентности ЭЭГ в отдельных частотных диапазонах. В частности, показана временная взаимосвязь между активацией селективного внимания (команда приготовиться) и осуществлением произвольного движения, а также изменение параметров этой взаимосвязи у больных с некоторыми видами двигательной патологии (больные спастической кривошеей).

Для решения проблемы низкой эффективности классического спектрального анализа, основанного на преобразовании Фурье в нашей работе предлагается использование алгоритмов искусственного интеллекта и методов машинного обучения на основе «свёрточной» нейронной сети. «Обучение» нейронной сети на основе данных биоэлектрической активности мозга здоровых и больных испытуемых при методе максимизации правдоподобия позволяет упростить задачу бинарной классификации (больной-здоровый) и количественно оценить вероятность развития БП.

Этапы работы:

1. Разработка протокола ЭЭГ исследования с применением сложно координационных «моторных» функциональных проб, сопряженных с актуализацией дефицитных функции. Формирование контрольной (условно здоровые) и опытной (БП) групп испытуемых. Регистрация ЭЭГ с применяем данного протокола в исследуемых группах.

2. Формирование на основе амплитудно-частотного анализа ЭЭГ матриц когерентности «пространственной синхронности» сигнала в различных областях мозга. Подготовка матриц когерентности для обработки при помощи алгоритмов искусственного интеллекта и первичного нахождения паттернов Болезни Паркинсона.

3. Разработка алгоритмов искусственного интеллекта и машинного обучения позволяющих на основе «свёрточной» нейронной сети диагностировать (предсказывать) БП. Верификация разработанного алгоритма на тестовых клинических данных ЭЭГ исследования пациентов на разных стадиях БП и испытуемых контрольной группы.

В исследовании приняли участие 32 пациента, с диагнозом болезнь Паркинсона, контрольную группу составили 18 условно здоровых испытуемых (аналогичной возрастной группы, не страдающие БП). В ходе исследования производили запись ЭЭГ в состоянии покоя с открытыми и закрытыми глазами, а также при подготовке и выполнении разработанной моторной пробы «Спираль Архимеда». Моторные пробы выполнялись как левой, так и правой рукой. Регистрация по 21 отведению (Fp1. Fpz, Fp2, F7, F3, Fz, F4, F8, 13, C3, Cz, C4, 14, T5, P3, Pz, P4, T6, O1, Oz, O2), референты A1 и A2. Электроды располагаются по схеме 10- 20%, схема реконструкции Base Monopolar.

Перед обработкой данных ЭЭГ исследования должно быть проведено удаление окуло- и миографических артефактов, а также частотная фильтрация в диапазоне от 0,5 до 45 Гц.

Требования к выполнению функциональных проб:

1. Тестирование начинается с команды «внимание», испытуемый ставит карандаш в

2. Центр модельного рисунка «спирали Архимеда» и готовится к выполнению движения.

3. Через 15 с дается команда «старт» после чего испытуемый начинает обводить рисунок спирали карандашом.

Во время подготовки и выполнения движения производит запись ЭЭГ. Тестирование проводится как правой, так и левой рукой. Фиксируется

время выполнения теста. Полученные данные будут обработаны с помощью методов вариационной статистики, позволяющих вычислять параметры достоверной значимости результатов исследования.

Результатом работы являются набор текстовых файлов для каждой функциональной пробы:

1. Текстовые файлы в кодировке CP1251 или UTF8 с матрицами когерентности 21 на 21 по семи частотным диапазонам, указанным выше, с указанием пола, возраста диагноза, стадии и формы заболевания (по Hoehn & Yahr) для каждого этапа функциональной пробы.

Алгоритм классификации

В качестве входных данных для обучения использовались матрицы когерентности 21 на 21, определенного частотного спектра для каждой пробы.

Перед процессом обучения был использован процесс аугментации данных для увеличения размера и разнообразия обучающих наборов данных. Были сгенерированы новые матрицы с помощью функции, добавляющей случайный шум к значениям массива в пределах экспериментально определенной погрешности аппарата: +-0.02 от значения когерентности. Эта функция применялась к обучающим и тестовым наборам данных для создания дополнительных расширенных выборок.

Стоит отметить, что данные одного и того же пациента были включены только в обучающий или только в тестовый набор данных, чтобы гарантировать, что модель не будет использовать данные конкретного пациента для определения результата. Дополняя наборы обучающих и тестовых данных, модель подвергалась воздействию более широкого диапазона вариаций данных и имела больше шансов обобщить новые данные.

Архитектура моделей convolutional neural network (CNN) была использовала стандартную для свёрточных сетей архитектуру, состоящая из трех последовательных применений двухмерных свёрточных слоев (Conv2D), слоев активации (Activation) и двухмерных субдискретизирующих слоев (MaxPooling2D), на каждом слое количество ядер увеличивалось в 2 раза. Модель состояла из четырех ветвей, каждая из которых представляла отдельный поток входных данных, для отдельной функциональной пробы, которые после извлечения особенностей объединялись и обрабатывались с помощью дополнительных плотных слоев для получения окончательного результата. Функции активации и выпадающие слои были включены для улучшения обобщения модели и уменьшения переобучения. В качестве

меры ошибки была использована средняя квадратическая ошибка, в качестве оптимизатора был использован ADAM (адаптивная оценка момента), основная метрика при обучении - точность классификации.

Модели CNN были реализованы на Python с использованием Keras с серверной частью TensorFlow и прошли примерно 2-минутное обучение на один вариант модели с использованием Google Colab (GPU: Nvidia K80, 2xVCPU Intel(R) Xeon(R) CPU @ 2.00GHz, 16 Гб Оперативной памяти). После обучения моделям потребовалось меньше секунды, для валидации на тестовой выборке.

Тестовая выборка генерировалась случайным образом, сохраняя баланс классов пациентов и контроля 7 к 3.

Для каждого используемого частотного диапазона (Δ (0,5–4 Гц) – дельта; θ (4–8 Гц.) – тета; α1 (8–9,5 Гц.) – альфа1; α2 (9,5-11) – альфа2; α3 (11–13 Гц.) – альфа3; β1 (13–24 Гц.) – бета1; β2 (24–34 Гц.) - бета2) производилась k-fold валидация путем генерации 10 случайных выборок тренировочных и тестовых данных в количестве 20 % (10 точек) от всех данных, сохраняя баланс классов в тестовой и тренировочной выборке. Для выборок отдельно производился процесс аугментации, указанный выше, было дополнительно сгенерировано матриц: 150 для тренировочной выборки, 50 для тестовой.

K-fold валидация использовалась из-за малого количество данных. Пациенты и контрольная группа вместе разделялись на 10 групп. Одна из групп выделялась для валидации, остальные использовались в обучении. Группы были независимо аугментированные. Результирующая точность валидации (процент успешных классификаций) записывалась для каждой группы.

Были представлены отчеты для всех частотных диапазонов и результаты работы лучшей модели для каждого диапазона.

Были проанализированы средние и минимальные ошибки и достоверность в различных частотных диапазонах, где соответственно, меньше ошибки - лучше и больше достоверность – лучше.

Результаты тестирования лучших моделей выявили общую проблему для всех моделей − низкую полноту для класса «Здоровый». Это связано с ограниченным объемом имеющихся данных. Примечательно, что все модели имеют оценку точности 1 для класса «Здоровый», что указывает на тенденцию идентифицировать людей как больных из-за дисбаланса данных по отношению к классу больных.

Обученные модели показали усредненную достоверность на *k-fold* валидации от 72 %, для не репрезентативных частотных диапазонов, до 79 % для диапазона 4.00–8.00 Гц., что минимум на 8 % выше базовой

оценки. Особенно высокий показатель достоверности в тета-диапазоне потенциально может быть объяснен синхронизацией тремора с тета-ритмом контралатерального полушария головного мозга, обнаруженной в работе Королева и Обухова [7].

Заключение

Показана возможность использования критерия когерентности биоэлектрической активности мозга в качестве информативного параметра при диагностике болезни Паркинсона (БП). Разработан новый протокол исследования электроэнцефалограммы (ЭЭГ), включающий сложно-координационные "моторные" функциональные пробы, связанные с актуализацией дефицитных функций. Предложен новый алгоритм распознавания признаков БП на основе данных ЭЭГ с применением свёрточной нейронной сети.

Полученные результаты могут быть использованы в качестве дополнительного критерия при диагностике БП, что повысит ее точность и своевременность. Они также подтверждают эффективность использования классических методов, таких как ЭЭГ, совместно с машинным обучением и нейронными сетями для повышения точности и эффективности диагностики. В будущем планируется расширение объема данных и продолжение исследования для улучшения точности и полноты моделей, а также расширения их применения в диагностике болезни Паркинсона и других нейродегенеративных заболеваний.

Список литературы

1. Fogelson N., Williams D., Tijssen M. et al. Spectral analysis reveals altered spectral EEG phenomena in dementia with Lewy bodies compared to Alzheimer's disease and normal aging. Clinical Neurophysiology, 2006.
2. Pezard L, Jech R, Ruzicka E. Quantitative EEG mapping in early stages of Parkinson's disease. Movement disorders, 2001.
3. Oswal A., Litvak V., Brown P. Synchronized neural oscillations and the pathophysiology of Parkinson's disease. Current opinion in neurology, 2014.
4. Обухов Ю., Гапоненко В., Лебедев М. и др. Вейвлет-анализ ЭЭГ в диагностике ранних стадий болезни Паркинсона. Вестник Санкт-Петербургского университета. Серия 14. Прикладная математика. Информатика. Процессы управления, 2010.
5. Голубев В.Л., Левин Я.И., Вейн А.М. Биомаркеры болезни Паркинсона: достижения и перспективы. Неврологический журнал, 1999.
6. Обухов, К.Ю. (2019). Методы электроэнцефалографической диагностики патологий головного мозга с применением алгоритмов машинного обучения: диссертация на соискание ученой степени кандидата наук: специальность 05.11.17.

Санкт-Петербургский государственный электротехнический университет «ЛЭТИ» им. В.И. Ульянова (Ленина).

7. Королев М.С., Обухов Ю.В. Характеристики нестабильности параметров вейвлет-спектра ЭЭГ при болезни Паркинсона на ранней стадии. Журнал высшей нервной деятельности имени И.П. Павлова, 2010.

Е.А. ИЛЛАРИОНОВ
Московский государственный университет им. М.В. Ломоносова
egor.illarionov@math.msu.ru

АДАПТИВНАЯ НЕЙРОСЕТЕВАЯ МОДЕЛЬ ДЛЯ ОЦИФРОВКИ РУКОПИСНОГО ТЕКСТА

Автоматическая оцифровка рукописного текста по сей день является трудной задачей, в том числе для моделей машинного обучения. Одним из факторов, негативно влияющих на точность модели, является сильная вариативность почерков разных авторов. При стандартном подходе модели машинного обучения обучаются на заранее подготовленной выборке. При работе с рукописным текстом обычно трудно гарантировать, что обучающая выборка покрывает все разнообразие почерков, с которыми предстоит работать модели. На практике это приводи к тому, что тексты с новым почерком, непохожим на те примеры, что были в выборке, распознаются существенно хуже. В нашей работе предлагается идея, как реализовать адаптивную нейросетевую модель, которая будет автоматически подстраиваться под новые стили почерков и другие особенности документа. Предлагаемая идея, разумеется, не является универсальной, однако в ряде задач может существенно повысить качество оцифровки текста. В работе данная модель применяется для оцифровки многостраничных рукописных каталогов с табличными данными о наблюдениях солнечной активности.

Ключевые слова: *нейронные сети, оцифровка рукописного текста.*

Введение

Задача оцифровки рукописного текста сегодня уже является классической в машинном обучении. Например, задача о построении модели по распознаванию рукописных цифр из каталога MNIST [1] входит во многие образовательные курсы по машинному обучению. Оказывается, что даже простые сверточные нейросетевые модели обеспечивают точность выше 95 %

(см. также [1]). Отсюда складывается впечатление, что задача, в целом, решена и будет достаточно лишь немного модифицировать модель или выборку, чтобы столь же успешно оцифровывать любой рукописный текст.

На практике дело обстоит существенно сложнее. Прежде всего отметим, что успех даже самых простых моделей на датасете MNIST является, скорее всего, не показателем универсальности моделей, а во многом обусловлен простотой (хотя и не сразу очевидной) самого датасета MNIST. В работе [2] исследовалась точность некоторых популярных нейросетевых моделей на датасете MNIST в зависимости от размера обучающей выборки. Было показано, что 10 % от датасета MNIST обеспечивают точность выше 97 % на оставшейся выборке. Причем этот показатель устойчив к различным случайным подвыборкам, из которых составлялся обучающий набор данных. Одним из выводов этой работы является то, что, по-видимому, примеры в датасете MNIST являются не настолько разнообразными, чтобы можно было судить о реальной обобщающей способности моделей к распознаванию рукописного текста.

К схожему выводу приходят авторы работы [3], в которой ставилась задача оцифровки рукописных таблиц с числовыми данными. Одной из первых и естественных попыток было разбить число на отдельные цифры и далее применить модель классификации цифр. В качестве обучающего набора был выбран датасет MNIST. Несмотря на то, что новая выборки была максимально приближена (по размеру изображений и гистограмме интенсивностей пикселей) к датасету MNIST и обученная модель давала высокую точность на тестовой части датасета MNIST, точность на новой выборке была существенно ниже. Ситуация исправилась только после того, как в обучающую выборку были включены размеченные примеры из новой выборки. Это, однако, не решило исходной задачи распознавания числа целиком, поскольку выяснилось, что разделения рукописного числа на цифры работает неустойчиво и даже при успешном разделении точность разделения числа целиком существенно ниже точности распознавания отдельных символов. Все это приводит к мыслям, что модели распознавания рукописных текстов должны включать новые идеи. Некоторые из этих идею и составляют содержание данной работы и являются развитием работы [4].

Постановка задачи и описание модели

В качестве конкретной задачи будет рассматриваться архив табличных рукописных записей из каталогов Цюрихской обсерватории. На обсерватории с конца 19 века и по первую половину 20 века проводились ежедневные

наблюдения Солнца, фиксировались положения различных активных областей на диске Солнца и результаты измерения координат заносились в таблицу. На рис. 1 приведен пример фрагмента одной из страниц. Из всего архива для анализа был выбран наиболее интересный с точки зрения солнечной физики период с 1887 по 1920 год, что составило более 10 тысяч страниц. Более подробное изложение физической стороны вопроса дано в работе [4].

Рис. 1. Фрагмент страницы с табличными данными из каталога Цюрихской обсерватории. Рамка синего цвета ограничивает ту область страницы, для которой ставится задача оцифровки данных

Первый необходимый шаг в решении задачи состоит в том, чтобы таблицу с числами разделить на изображения отдельных чисел, которые будут подаваться на вход модели оцифровки. Можно заметить, что на странице есть разлиновка строк и столбцов, выполненная карандашом. За редким исключением эта разлиновка на отсканированной странице идет почти параллельно сторонам отсканированного изображения, что несколько упрощает дело. Для выделения протяженных вертикальных и горизонтальных линий использовалась комбинация фильтра Канни [5], который помогает обнаруживать места с большим градиентом на изображении, а затем применялось два сверточных ядра, один для вертикальных, а другой для горизонтальных

линий. После этого изображение суммировалось отдельно по строкам и отдельно по столбцам. На рис. 2 приведен пример страницы и суммированных рядов. Пики в рядах локализуют протяженные вертикальные и горизонтальные линии на исходном изображении. Далее таблица разбивается на набор ячеек, содержащих по одному числу. Для удобства изображения каждой отдельной ячейки приводилось к одному размеру – 64 пикселя по ширине и 32 по высоте.

Рис. 2. Пример работы метода детекции вертикальных линий на странице. Внизу показан фрагмент страницы каталога. Зеленой линией наверху показан результат свертки изображения с вертикальным ядром, синие линии отвечают выраженным локальным максимумам зеленого графика

Всего мы получили свыше 3 млн примеров изображений рукописных чисел. Часть из этих изображений (около 8 тысяч) были размечены вручную (картинке вручную сопоставлялось число, на ней изображенное).

В качестве базовой модели оцифровки мы используем сверточно-рекуррентную модель (CRNN) по типу той, что была предложена в работе [6]. В нашей реализации модель устроена следующим образом. Модель нейронной сети состоит из трех блоков. В первом блоке идет последовательность сверточных слоев и слоев понижения размера. Второй блок – это два двунаправленных рекуррентных слоя. Последний блок – полносвязный слой.

Сверточные слои преобразуют входной тензор размера (1, 32, 64) в тензор размера (128, 1, 64). Мы интерпретируем его как 128 признаков, приписываемых столбцам изображения. Затем мы применяем рекуррентные слои для получения тензора размера (512, 64), который интерпретируется как последовательность (размера 64) векторов-признаков (размера 512), полученных из последовательности столбцов пикселей изображения (отметим, что здесь не предполагается однозначное соответствие между элементами этой последовательности и столбцами изображения). Наконец, выходной слой преобразует 512 параметров в 12, которые представляют собой оценки вероятности классов, где классами являются ‘0’, ‘1’, ..., ‘9’, знак минус ‘–’ и специальный пустой символ ‘*’. Эти 12 символов образуют минимально достаточный набор для декодирования числа. Последовательность размером 64 из 12 оценок образует тепловую карту размером 64 × 12. Схема модели представлена на рис. 3.

Рис. 3. Схема модели CRNN. Входное одноканальное изображение размера 64×32 пикселя проходит через последовательность сверточных слоев и слоев понижения размерности и преобразуется к тензору размера 128×1×64. Далее следуют рекуррентные слои, которые приводят к тензору 512×64. Полносвязный слой 512×12 формирует выходной массив размером 512×12

Тепловая карта еще не вполне однозначно соответствует какому-либо числу. В обычных моделях классификации для принятия решения о классе достаточно выбрать класс, который отвечает наибольшему значению в выходном векторе вероятностей. В случае тепловой карты задача усложняется хотя бы потому, что заранее неизвестно, сколько символов (цифр) изображено на картинке. Соответственно, и функция потерь при обучении используется более сложная, чем стандартная функция потерь для задач классификации или регрессии. Для обучения модели CRNN использовалась функция потерь connectionist temporal classification (CTC), предложенная в работе [7].

Тестирование обученной модели на тестовой части размеченной выборки показало высокую, на первый взгляд, точность – 97 %. Под точностью понимается процент правильно распознанных чисел с учетом знака. Однако тестирование модели на страницах каталогов показало, что эта точность распределена далеко не равномерно и по факту существенно ниже. Выяснилось, что есть страницы, которые распознаются в целом хорошо с редкими ошибками. Но есть и страницы (или части страниц), которые распознаются крайне плохо целиком. Иногда мы связываем это с резким изменением фона страницы, иногда с новым почерком, иногда с небрежностью записей. Отметим, что эта проблемы качественно не устранялась ни за счет расширения выборки, ни за счет аугментации обучающих данных.

Суть данной работы в том, чтобы предложить решение, которое позволит CRNN модели адаптироваться под новые условия страниц и стили почерка и повысит качество распознавания текста в целом.

Ключом к решению проблемы стало то, что числа в каталогах не случайные, а обладают определенными связями. Точнее говоря, в нашем случае между некоторыми колонками таблицы есть точная линейная связь. Коэффициенты этой связи заранее не известны и для каждой страницы они могут быть новые. С одной стороны, это выглядит как сильная подсказка, однако можно предположить, что реальные документы, для которых актуальна задача оцифровки, также состоят не из случайных записей и содержат определенные взаимосвязи. Далее мы предлагаем способ, как можно учитывать эти взаимосвязи для построения более точных моделей.

Наш подход состоит в том, что сначала новая страница оцифровывается с помощью базовой (предобученной) модели. Мы исходим из того, что хотя точность этой модели может быть недостаточно высокой, однако этой точности достаточно, чтобы оценить коэффициенты линейной связи между столбцами новой страницы.

Далее мы запускаем процедуру дообучения модели. Суть ее в том, что, зная параметры линейной связи между столбцами таблицы, мы можем автоматически составить обучающий датасет из примеров изображений и значений чисел с изображений. Поясним правило построение датасета на простом примере. Пусть у нас есть два столбца, A и B, между которыми мы заранее знаем, что есть точная связь, например, B=2A, т.е. значения в столбце B являются удвоением значений в столбце A. Мы делаем прогноз базовой моделью и получаем значения, которые обозначим a и b для столбцов A и B соответственно. Теперь соберем датасет из пар (изображение числа из столбца B, число 2a) и из пар (изображение из столбца A, число b/2). На этом датасете проведем один цикл обучения модели. Идея этого

шага в том, чтобы модель научилась видеть не просто какие-то числа, а такие числа, между которыми выполняется известная связь. После одного цикла обучения мы делаем прогноз текущей моделью на всем столбце A и B, повторяем процедуру сборки датасета из пар (B, число 2a) и пар (A, b/2) и делаем новый цикл обучения. Так мы повторяем до тех пор, пока различие между значениями a и b/2 не минимизируются.

В следующем разделе мы покажем, что данная процедура действительно приводит к лучшим результатам по сравнению с базовой моделью. Пока отметим важную особенность предложенного метода – он не требует ручной разметки новых изображений для адаптации модели к особенностям новых данных.

Результаты

Предложенная методика адаптации была апробирована в работе [4]. На рис. 4 показан характерный пример, когда адаптированная модель дает существенно лучший результат распознавания чисел по сравнению с базовой моделью. Отметим, что для иллюстрации был специально выбран пример страницы, на котором базовая модель показывает низкое качество (это может быть обусловлено новым почерком, цветом чернил или фона страницы). Для большинства страниц ситуация выглядит значительно лучше, и базовая модель допускает лишь эпизодические ошибки. Однако подобные примеры с физической стороны дела означают, что мы целиком теряем ряд дней в истории наблюдений, а не часть наблюдений в течение дня. Именно в этих ситуациях предложенный метод адаптации дает наибольший эффект для восполнения пропущенных или неверно оцифрованных значений.

Оцифровка архива позволила нам составить новый большой датасет с примерами изображений рукописных чисел и значений чисел на картинке. Мы включили в датасет 100 тысяч примеров, случайно выбранных из всего массива страниц. Для отбора использовались только не значения, в которых уверенность модели равна 1 (см. более подробно про оценку уверенности в работе [4]). Это, конечно, не гарантирует полного отсутствия ошибок в разметке, однако, по нашим оценкам, доля ошибок не должна превышать 1 %. На рис. 6 приведены некоторые изображения из нового датасета. В данной работе мы впервые публикуем этот датасет, он доступен по ссылке https://github.com/observethesun/handwritten_numbers.

Рис. 4. Пример страницы из каталога, на которой появляется почерк, существенно отличных от примеров из обучающей выборки базовой модели. Базовая модель (слева) допускает много ошибок и более того, для многих чисел результат раскодирования тепловой карты возвращает пустое значение (т.е. модель не видит вовсе никакого числа на картинке). После автоматической процедуры адаптации (справа) ситуация существенно улучшается. Цвет фона ячеек характеризует степень уверенности модели в ответе (темнее фон – меньше уверенность)

Рис. 5. Примеры изображений рукописных чисел из аннотированного датасета

Выводы

В данной работе мы рассматриваем вопрос адаптации моделей машинного обучения к данным, выходящим за рамки разнообразия примеров из обучающего датасета. Подобная задача встречается, например, при оцифровке рукописных документов, составленных большим числом авторов. Далеко не всегда этот вопрос решается простым расширением обучающего набора данных хотя бы потому, что этот процесс может оказаться весьма трудоемким. Однако если в данных есть определенные взаимосвязи, этим можно воспользоваться для адаптации (дообучения) модели без необходимости ручной доразметки данных.

В работе мы приводим пример реализации автоматической процедуры адаптации нейросетевой модели на основе большого набора рукописных табличных каталогов Цюрихской обсерватории. Предварительно обученная модель использовалась для первоначальной оцифровки текста. Затем, на каждой странице каталога модель автоматически дообучалась так, чтобы оцифрованные значения лучше укладывались в закономерности, известные априори (в нашем случае, вытекающие из физического контекста задачи). Таким образом, мы смогли избежать трудоемкого процесса ручного сбора данных с примерами всех возможных вариантов написания текста и ограничиться только относительно небольшим набором данных для обучения базовой модели. В результате адаптации базовой модели мы получили стабильно высокое качество, которое не уменьшалось при появлении новых стилей почерка или изменении фона текста. Предложенная методика хотя и опирается на особенности конкретного набора данных, однако имеет перспективы реализации для текстовых документов различной природы.

В дополнение к данной работе мы впервые публикуем датасет, состоящий из 100 тысяч примеров изображений рукописных чисел и соответствующих значений чисел на картинках. Датасет доступен по ссылке https://github.com/observethesun/handwritten_numbers.

Список литературы

1. Y. LeCun, L. Bottou, Y. Bengio, and P. Haffner. Gradient-based learning applied to document recognition. Proceedings of the IEEE, 86(11):2278-2324, 1998.
2. E. Illarionov, R. Khudorozhkov. Not quite unreasonable effectiveness of machine learning algorithms. arXiv:1804.02543, doi:10.48550/arXiv.1804.02543, 2018.
3. Г. Нуждов. Распознавание рукописных чисел в архивах данных солнечной активности методами компьютерного зрения. Дипломная работа, МГУ, механико-математический факультет, 2021.

4. E. Illarionov, R. Arlt. Reconstruction of the Solar Activity from the Catalogs of the Zurich Observatory. Solar Physics 297, 79. 2022. https://doi.org/10.1007/s11207-022-02015-3.

5. J. Canny. A computational approach to edge detection. IEEE Transactions on Pattern Analysis and Machine Intelligence, PAMI-8(6):679–698, 1986. doi:10.1109/TPAMI.1986.4767851.

6. B. Shi, X. Bai, and C. Yao. An End-to-End Trainable Neural Network for Image-based Sequence Recognition and Its Application to Scene Text Recognition. arXiv:1507.05717, 2015.

7. Graves, S. Fernandez, and F. Gomez. Connectionist temporal classification: Labelling unsegmented sequence data with recurrent neural networks. In Proceedings of the International Conference on Machine Learning, ICML 2006, pages 369–376, 2006.

М.Х. САЙБОДАЛОВ, Я.М. КАРАНДАШЕВ

Научно-исследовательский институт системных исследований РАН[2], Москва

Российский университет дружбы народов имени Патриса Лумумбы, Москва

maratsaibodalov@gmail.com; karandashev@niisi.ras.ru

ПРИМЕНЕНИЕ САМООБУЧАЮЩИХСЯ АЛГОРИТМОВ ДЛЯ ДЕТЕКЦИИ АНОМАЛИЙ НА РЕНТГЕНОВСКИХ СНИМКАХ

В данной работе рассматривается задача нахождения инородных объектов на рентгеновских снимках, полученных со сканеров персонального досмотра. Такие сканеры используются на объектах, требующих повышенного контроля безопасности. Имеющиеся данные имеют ряд проблем, которые описываются и решаются в тексте. В данной работе будут рассматриваться исключительно самообучающиеся алгоритмы детекции аномалий, которые обучаются на данных, не содержащих аномалии. Такие модели, в отличии от алгоритмов обучения с учителем, не требуют большого количества размеченных данных для обучения.

Ключевые слова: *глубокие нейронные сети, обучение без учителя, самообучащиеся алгоритмы, сегментация изображений, выделение аномалий, рентгеновские снимки.*

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

Введение

В данной работе рассматривается проблема обнаружения аномалий на рентгеновских изображениях, полученных сканерами персонального досмотра. Сканеры персонального досмотра (СПД) часто используются на объектах, требующих повышенного контроля безопасности. Они позволяют быстро получить рентгеновский снимок человека, на котором оператор СПД может увидеть все инородные предметы на теле человека и визуально подтвердить или опровергнуть наличие каких-либо запрещенных предметов. Процесс имеет ряд существенных недостатков, связанных с человеческим фактором: качественный анализ изображения требует значительного времени и внимания, что приводит к быстрой утомляемости оператора и может негативно сказаться на качестве анализа изображения. Этот процесс можно значительно автоматизировать, что удешевит его для организации и сделает более удобным для оператора. Для решения этой задачи использовались глубокие нейронные сети.

Обнаружение аномалий − это проблема, которая возникает в самых разных областях, где необходимо идентифицировать необычные или неожиданные события, поведение или закономерности в данных. Некоторые из областей, где обычно применяется обнаружение аномалий, включают:

- Кибербезопасность: обнаружение аномалий используется для выявления аномального сетевого трафика, попыток несанкционированного доступа и подозрительных действий в компьютерных системах.
- Обнаружение мошенничества. Обнаружение аномалий используется для выявления мошеннических транзакций, подозрительной финансовой деятельности и схем отмывания денег.
- Производство: обнаружение аномалий используется для выявления дефектов в производственных процессах, дефектных продуктов и ненормального поведения оборудования.
- Здравоохранение. Обнаружение аномалий используется для выявления заболеваний, требующих неотложной помощи, таких как сердечные приступы, инсульты или другие острые состояния.

Это всего лишь несколько примеров из многих областей, где используется обнаружение аномалий. В общем, любая область, которая имеет дело с большими объемами данных, может выиграть от применения методов обнаружения аномалий.

Обычно эти задачи решаются с помощью алгоритмов обучения с учителем [4], для обучения которых необходимо иметь огромное количество размеченных данных. Очевидно, что разметка тысяч изображений может по-

требовать финансовых и временных затрат. Также разметка является длительным и утомительным процессом. Более того, алгоритмы обучения с учителем требуют большое количество образцов аномалий определенного рода, в нашем случае, например, оружия и металлических предметов, а образцов с такими аномалиями не так много.

1. Постановка задачи и описание алгоритма

Требуется создать автоматизированное решение поиска запрещённых (инородных) объектов на изображениях, полученных из сканеров персонального досмотра. То есть необходимо разработать решение, связывающее с каждым рентгеновским изображением бинарную маску, истинные значения которой соответствуют пикселям, на которых присутствуют посторонние предметы, такие как телефоны, оружие, металлические предметы и т. д. В дальнейшем мы будем называть такие объекты аномалиями. Метриками качества работы алгоритмов будут служить как метрики совпадения обнаруженных аномалий с размеченной маской, так и скорость работы алгоритмов. На рис. 1, 3–5 можно увидеть пример исходного изображения и маски к нему.

Из-за нехватки изображений, содержащих наиболее важные аномалии, было принято решение использовать исключительно методы обучения без учителя, которые не требуют большого количества размеченных данных. Методика обучения таких моделей заключается в том, чтобы натренировать алгоритм выделять только признаки человеческого тела. То есть обучение модели происходит на наборе данных, которые не содержат каких-либо аномалий. Затем, когда модель обучена определять признаки человеческого тела, мы можем подавать в нее изображения, содержащее аномалии и, так как ранее модель не встречала подобных инородных элементов, она будет определять инородные предметы как аномалии.

В данной работе рассматриваются исключительно методы обучения без учителя, такие как AE, VAE, PatchSVDD. Все вычисления проводились с помощью современного высокоуровнего языка программирования Python версии 3.10. Для методов анализа изображений использовалась библиотека skimage. Для работы с нейронными сетями задействована библиотека Pytorch.

2. Описание данных

Данные представляют из себя изображения в формате .tiff. Все снимки одноканальные, то есть в них содержится только значение интенсивности пикселя. Значения интенсивности варьируются от 0 до 216. Размер изображений различный, но составляет в среднем 1700 на 600 пикселей. Всего предоставлено 1643 изображения. Все предоставленные снимки сделаны со спины человека, и в полный рост. На 1343 снимках есть те или иные объекты, не принадлежащие телу человеку, например застёжки, пуговицы, ножи, проволока, пистолеты. Оставшиеся изображения не содержат никаких посторонних объектов. Снимки были размечены с помощью сервиса Яндекс.Толока [14]. Данный ресурс позволяет быстро разметить большой объём данных. По результатам разметки получены булевы маски, где значение 1 соответствует инородному объекту, значение 0 – отсутствию инородного объекта. Такие размеченные маски мы будем использовать для анализа результатов моделей.

Рис. 1. Результат работы АЕ с функцией потерь SSIM.
Левый: предобработанный исходный снимок,
посередине: размеченная вручную маска, справа: результат работы АЕ

Для предобработки данных использовалась последовательность из нескольких операций выравнивания гистограмм и обрезания гистограммы по

пороговому значению. Более подробное описание используемой предобработки описано здесь [15]. Примеры изображений предобработанных снимков и масок к ним представлены на рис. 1–5.

Рис. 2. Примеры патчей

Рис. 3. Слева и посередине – исходное изображение и маска.
Справа: результат работы VAE

Рис. 4. Результат работы Patch SVDD. Слева и посередине – исходное изображение и маска. Справа: результат работы Patch SVDD

Рис. 5. Результат работы Patch SVDD. Слева и посередине – исходное изображение и маска. Справа: результат работы Patch SVDD

3. Алгоритмы детекции аномалий на рентгеновских снимках

3.1. Автокодировщик (Autoencoder)

Автокодировщик (AE) будет первой рассмотренной архитектурой алгоритма обучения нейронных сетей без учителя. Автокодировщик − это популярный тип архитектуры нейронной сети, используемый в обучении без учителя, где цель состоит в том, чтобы получить сжатое представление входных данных путем их кодирования в низкоразмерное скрытое пространство, а затем декодировать обратно в исходное пространство данных. Сеть обучена минимизировать ошибку реконструкции (например, MSE или SSIM, которая используется в данной работе и описана ниже) между входными и выходными данными, что означает, что она учится фиксировать основные характеристики входных данных, отбрасывая шум и несущественные детали. В настоящей работе используется следующая функция ошибки:

$$SSIM(x,y) = \frac{(2\mu_x\mu_y + c_1)(2\sigma_{xy} + c_2)}{(\mu_x^2 + \mu_y^2 + c_1)(\sigma_x^2 + \sigma_y^2 + c_2)}, \quad (1)$$

где μ_x, μ_y, σ_x^2, σ_y^2, σ_{xy} − средние, дисперсии и ковариация значений x и y, $c_1 = (k_1 L)^2$, $c_2 = (k_2 L)^2$ − две переменных для стабилизации деления в знаменателе, L − динамический диапазон значений пикселей (обычно $2^{(\text{bits per pixel})} - 1$), $k_1 = 0.01$, $k_2 = 0.03$ – константы по умолчанию.

Данная модель обучалась исключительно на данных без аномалий. При тестировании обученной модели, в нее подаются изображения, содержащие аномалии. Идея заключается в том, что алгоритм, обученный восстанавливать изображения без аномалий (т.е. только человеческое тело), не сможет восстановить аномалии и, таким образом, будет получено изображение, похожее на входное, но без аномалий. Затем, карта аномалий может быть получена путем вычитания из исходного изображения то, которое обработала модель [2].

Результат работы модели можно увидеть на рисунке 1. Можно заметить, что модель хорошо выделяет аномалии, находящиеся вне человеческого тела, и даже выделяет некоторые аномалии на теле. Но, тем не менее, большое количество аномалий не было обнаружено, а также присутствует немалое количество ложноположительных обнаружений (можно увидеть, что алгоритм выделяет части пола или части тела человека). Это происходит из-за того, что данные слишком разные: люди стоят в разных позах, снимки делались на разных сканерах, из-за чего на некоторых снимках высота пола

может отличаться. AE обрабатывает изображение достаточно быстро (около 3 секунд на одно изображение), но результат работы неидеален, большое количество аномалий не было обнаружено.

Можно увидеть, что на более сложных изображениях сегментация алгоритма проводится значительно лучше, чем стандартным AE. Здесь так же присутствует немало ложноположительных сегментация, но, при этом, было выделено куда больше аномалий, находящихся на теле. Данная функция потерь будет использована и далее.

3.2. Вариационный Автокодировшик (VAE)

Вариационный автокодировщик или VAE − это генеративная модель, которая часто используется в области детекции аномалий [2]. Архитектура модели похожа на автокодировщик, однако, отличие этих алгоритмов заключается в том, как кодировщик получает латентные векторы. Вместо того, чтобы выводить векторы в латентное пространство, кодировщик VAE выводит параметры заранее определенного распределения в латентном пространстве для каждого входа. Затем VAE накладывает ограничение на это латентное распределение, заставляя его быть нормальным распределением.

На этом шаге было принято решение подавать в модель части изображения, так как глубокие нейронные сети намного лучше работают с небольшими изображениями (в нашем случае с частями тела), нежели с целым человеческим телом [3], [8].

Исходные данные были разбиты на маленькие изображения и нейронная сеть обучалась восстанавливать эти небольшие части (патчи) изображения. После обучения, в нейронную сеть подавалось целое изображение, которое затем разбивалось на патчи, все эти патчи восстанавливались по отдельности и затем снова объединялись в одно изображение. Данную модель мы будем называть Patch VAE.

Как можно видеть на рис. 3, результат работы алгоритма значительно лучше, нежели результаты AE. Данный алгоритм обнаруживает большее количество аномалий, но все еще есть проблема с обнаружением аномалий, находящихся на теле. Карты аномалий были получены таким же образом, как и с AE, т.е. из сходного изображения вычиталось восстановленное моделью.

Стоит заметить, что использование подхода с разделением исходного изображения на патчи существенно снизило количество ложноположительных обнаружений по сравнению с обычным автокодировщиком. Время

обработки одного изображения фактически не отличается от автокодировщика и составляет 3.5 секунды.

3.3. Patch SVDD

Архитектура данной нейронной сети была описана в [8]. В оригинальной статье модель обучалась на датасете MVTEC AD [13]. Было принято решение попробовать применить данную модель к нашим рентгеновским данным.

Patch SVDD (Support Vector Data Description) − это модель глубокого обучения, которая сочетает в себе концепцию декомпозиции патчей и алгоритм SVDD для обнаружения аномалий. Алгоритм SVDD − это алгоритм классификации одного класса, целью которого является изучение жесткой границы вокруг набора нормальных данных.

Patch SVDD сначала разбивает входные данные на набор перекрывающихся патчей фиксированного размера. Затем каждый патч проходит через кодировщик (Encoder) патчей, который сопоставляет патч с низкоразмерным представлением латентного пространства. Кодировщики патчей обучаются с использованием ошибки реконструкции в качестве функции потерь, что побуждает алгоритм научиться определять сжатое и информативное представление входных патчей.

Затем сжатые представления патчей используются для обучения модели описания данных опорных векторов (SVDD). Модель SVDD учится строить жесткую границу гиперсферы вокруг нормальных данных в латентном пространстве. Цель состоит в том, чтобы минимизировать расстояние между центром гиперсферы и нормальными точками данных при максимальном расстоянии между центром и любыми потенциальными аномальными точками данных.

Во время тестирования входные данные разбиваются на патчи и передаются через кодировщик патчей для получения представлений скрытого пространства. Затем представления скрытого пространства передаются через модель SVDD, и вычисляется расстояние между точкой данных и центром гиперсферы. Если расстояние превышает предопределенный порог, точка данных помечается как аномалия.

При обучении данной модели использовалась та же техника, что и ранее: обучение проводилось на данных, не содержащих аномалии, модель училась определять ключевые признаки человеческого тела. При тестировании объекты, не относящиеся к человеческому телу, определялись как аномалии. Результат работы показан на рис. 4–5 и выглядит идеально.

Как можно увидеть по табл. 1, алгоритм Patch SVDD лучше всего справляется с задачей детекции аномалий в сравнении с другими алгоритмами, однако время на его обучение и обработку одного изображения значительно выше, чем у конкурентов. Тесты проводились на 50 изображениях из тестовой выборки, каждое из которых являлось маской аномалий и сравнивалось с размеченной маской.

Таблица 1

Сравнение алгоритмов AE SSIM, Patch VAE и Patch SVDD

	AE SSIM	PatchMAE	PatchSVDD
Время обучения, 100 эпох	1ч	1ч 45м	9ч 23м
Время обработки одного изображения, сек	4	5	15
IoU	0.71	0.69	0.92
SSIM	0.68	0.73	0.94

Заключение

Были разработаны алгоритмы обучения без учителя для детекции аномалий на рентгеновских снимках. Основной сложностью использования алгоритмов обучения без учителя является необходимость отбора данных, не содержащих аномалии и подбор правильной архитектуры. Было показано, что такие алгоритмы способны справляться с задачей сегментации изображения наравне с алгоритмами обучения с учителем, которые требуют значительно больших ресурсов, а также большого количества размеченных данных для обучения модели.

Список литературы

1. Lu, Yuchen, и Peng Xu. Anomaly detection for skin disease images using variational autoencoder. arXiv, 2018.
2. Luo, Jintao, и др. Texture and Semantic Convolutional Autoencoder for Anomaly Detection and Segmentation. IET Computer Vision, 2023.
3. Roth, Karsten, и др. Towards total recall in industrial anomaly detection. 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), IEEE, 2022.
4. S. B. Kotsiantis, Supervised Machine Learning: A Review of Classification Techniques,Informatica, Vol.31, No.3. P. 249–26, 2007.

5. Barlow, H. B. Unsupervised learning, Neural computation, Vol.1, No.3. P. 295–311, 1989.

6. Cao Y, Wan Q, Shen W and Gao L. Informative knowledge distillation for image anomaly segmentation. Knowledge-Based Systems, 2022.

7. Avola D, Cascio M, Cinque L, Fagioli A, Foresti G, Marini M and Rossi F. Real-time deep learning method for automated detection and localization of structural defects in manufactured products. Computers and Industrial Engineering, 2022.

8. J. Yi and S. Yoon,"Patch svdd: Patch-level svdd for anomaly detection and segmentation, in Proceedings of the Asian Conference on Computer Vision, 2020.

9. Krizhevsky, G. Hinton et al., Learning multiple layers of features from tiny images, 2009.

10. D. Abati, A. Porrello, S. Calderara, and R. Cucchiara, Latent space autoregression for novelty detection, in Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2019.

11. Sharma, N. and Aggarwal, L. M., Automated medical image segmentation techniques, Journal of Medical Physics / Association of Medical Physicists of India 35(1), 3–14, 2010.

12. Badrinarayanan, V., Kendall, A., and Cipolla, R., Segnet: A deep convolutional encoder-decoder architecture for image segmentation, IEEE Transactions on Pattern Analysis and Machine Intelligence 39(12), 2481–2495, 2017.

13. P. Bergmann, M. Fauser, D. Sattlegger and C. Steger, MVTec AD — A Comprehensive Real-World Dataset for Unsupervised Anomaly Detection, 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), Long Beach, CA, USA, 2019.

14. Яндекс Толока, Яндекс Толока, https://toloka.ai/

15. Марков А.С., Котляров Е.Ю., Аносова Н.П., Попов В.А., Карандашев Я.М., Апушкинская Д.Е. Использование нейронных сетей для выявления аномалий на рентгеновских снимках, полученных на сканерах персонального досмотра. Автоматика и телемеханика, 2022, № 10, стр. 23-34. DOI: 10.31857/S0005231022100038.

В.В. ХРЯЩЕВ

Ярославский государственный университет им. П.Г. Демидова

v.khryashchev@uniyar.ac.ru

ИССЛЕДОВАНИЕ НЕЙРОСЕТЕВЫХ АЛГОРИТМОВ ДЛЯ СИСТЕМЫ ПОДДЕРЖКИ ПРИНЯТИЯ ВРАЧЕБНОГО РЕШЕНИЯ ПРИ ИССЛЕДОВАНИИ ЖЕЛУДКА В ЭНДОСКОПИИ

На современном этапе широкое распространение при проведении эндоскопических исследований получают системы поддержки принятия вра-

чебного решения. В настоящем исследовании рассматривается задача обнаружения патологий желудка на эндоскопических видеоданных. Проведен анализ эффективности использования архитектур сверточных нейронных сетей SSD и EfficientDet применительно к этой задаче. Для обучения и тестирования алгоритмов глубокого машинного обучения использовались 54 видеозаписи исследований желудка.

Ключевые слова: *нейросетевые детекторы объектов, эндоскопические изображения, архитектура SSD, архитектура EfficientDet.*

Введение

В настоящее время актуальной научно-технической задачей является применение методов глубокого машинного обучения для построения алгоритмов анализа изображений и видеоданных в различных медицинских системах [1, 2]. Так, например, большое число исследований посвящено анализу использования систем искусственного интеллекта в качестве модуля поддержки принятия врачебного решения при эндоскопическом исследовании желудка [3–5]. Задача ранней диагностика рака желудка является крайне актуальной и для ее решения используется современное высокотехнологичное оборудование, включая методы узкоспектральной и увеличительной эндоскопии [6]. Подобная диагностика относится к медицинским исследованиям экспертного уровня, что требует привлечения опытных врачей-эндоскопистов высокой квалификации. Это связано со значительной трудоемкостью интерпретации видеоданных ввиду высокой вариативности эндоскопических изображений, которые также подвержены воздействию различных артефактов [7–9].

Использование автоматических методов детектирования и классификации объектов на видеоизображениях в эндоскопии способно уменьшить влияние человеческого фактора, увеличить итоговую точность медицинской диагностики, снизить временные затраты на проведение исследования. Кроме того, подобные системы могут успешно использоваться для обучения начинающих специалистов в данной области медицины и совершенствования навыков уже имеющегося медицинского персонала [10]. Это позволит в уже в ближайшей перспективе использовать данный тип современной диагностики для массовых (скрининговых) исследований, что повлечет за собой увеличение процента обнаружения онкологических заболеваний на ранней стадии их развития.

Согласно предыдущим результатам тестирования [7, 9, 11] лучшие показатели метрик соответствовали подходам на основе SSD-VGG16-300 и RetinaNet-ResNet50.

В рамках данной работы приведены результаты дальнейших исследований по выбору архитектур и соответствующих параметров сверточных нейронных сетей (СНС). Конечная цель исследований – получить оптимальное соотношение между вычислительной сложностью алгоритма с одной стороны и точностью/устойчивостью с другой. Под устойчивостью в данном случае будем понимать робастность нейросетевой модели [12], т.е. возможность модели воспроизводить результаты по используемым метрикам качества для различных наборов эндоскопических изображений желудка определенного типа (разные пациенты, разные эндоскопические аппараты, наличие/отсутствие оптического увеличения при исследовании). Для обучения и тестирования использовалась собственная база эндоскопических изображений, описанная ниже.

База эндоскопических изображений желудка для обучения и тестирования нейронных сетей

Для обучения и тестирования нейросетевых алгоритмов была собрана база эндоскопических изображений слизистой оболочки желудка. Для создания базы использовались 54 видеозаписи исследований, проведенных в эндоскопическом отделении Ярославской областной клинической онкологической больницы (ЯОКОБ).

Для сбора базы использовались эндоскопические аппараты OLYMPUS EXERA III GIF-Q180 и OLYMPUS EXERA III GIF-HQ190 со следующими режимами работы: осмотр в белом свете и в узком спектре света (NBI – Narrow Band Imaging); исследования без увеличения и с 65-кратным увеличением. Разрешение получаемых видеоизображений составляло 626x532 пикселей.

Из фрагментов видеоданных, получаемых с эндоскопа, выбирался каждый пятый кадр, в каждом из которых врач-эксперт выделял обрамляющей прямоугольной рамкой патологии одного из трех классов, рассматриваемых в данном исследовании, – ранний рак (всего 902 кадра), рак (всего 297 кадров), иная патология, включающая в себя изображения следующих видов патологий: кишечная метаплазия, аденома, полип, эрозия, язва, гиперплазия, ксантома (всего 1772 кадра). Таким образом, в результате извлечения кадров из видеопоследовательностей эндоскопических исследований желудка, была получена база изображений размером 2971 кадров. Примеры

размеченных врачами патологий в виде прямоугольных областей на изображениях из собранной базы приведены на рис. 1.

а *б* *в* *г*

Рис. 1. Примеры патологий из собранной базы изображений желудка:
а – ранний рак желудка; *б* – рак желудка;
в – эрозия желудка; *г* – кишечная метаплазия

Моделирование нейросетевых архитектур

Ниже приводятся результаты исследования четырех алгоритмов на основе сверточной нейронной сети SSD. В качестве базовых сетей были рассмотрены такие сверточные нейронные архитектуры, как VGG16, VGG19 [13], MobileNetV2 [14], Xception [15].

Алгоритм на основе архитектуры SSD с базовой сетью VGG16

Для построения первой вариации алгоритма обнаружения патологий слизистой оболочки желудка при проведении эндоскопического исследования была выбрана сеть SSD с базовой сетью VGG16 [13], размер входного слоя которой составил 300x300 пикселей.

В связи с тем, что разрешение кадра видеоданных в данной работе составляет 626x532 пикселей, было принято решение использовать в исследовании помимо стандартной SSD-300 также архитектуру SSD с базовой сетью VGG16, размер входного слоя которой составляет 512x512 пикселей. При использовании VGG16-512 в качестве базовой сети появляется еще один дополнительный масштаб карт признаков для детектирования.

Алгоритм на основе архитектуры SSD с базовой сетью VGG19

По сравнению с AlexNet, VGG-19 представляет собой более глубокую СНС с большим количеством слоев. В модели VGG-19 содержится всего 138 миллионов параметров, эта модель обучается на подмножестве базы данных ImageNet [16] и может классифицировать изображения по 1000 категориям объектов. В данной работе усеченная сеть VGG19 была использована в архитектуре SSD как базовая часть для выделения признаков из эндоскопических изображений.

Алгоритм на основе архитектуры SSD с базовой сетью MobileNetV2

Архитектура MobileNetV2 – второе поколение нейросетевых алгоритмов семейства MobileNets, которое позволяет достигать примерно такой же точности распознавания при ещё большей скорости работы за счет добавления пропускных соединений, позволяющих эффективнее пропускать информацию через сеть при ее обучении и корректировке весов. Как и в MobileNetV1, начальной модели из семейства сетей MobileNets, в архитектуре сети MobileNetV2 используется 2 типа сверточных блоков: с шагом 1 и с шагом 2.

Для архитектуры MobileNetV2 вычислительная сложность при использовании подобного подхода падает в 8–9 раз по сравнению с использованием стандартной свертки при незначительной потере точности.

Алгоритм на основе архитектуры SSD с базовой сетью Xception

Архитектура Xception – компактная глубокая СНС, предложенная создателем популярной библиотеки для алгоритмов глубокого обучения Keras [17]. Архитектура Xception имеет 36 сверточных слоев, образующих базу выделения признаков сети. Эти 36 сверточных слоев структурированы в 14 модулей, каждый из которых имеет линейные остаточные связи вокруг них, кроме первого и последнего модулей. Иными словами, архитектура Xception – это линейный стек разделимых по глубине сверточных слев с остаточными связями. При прохождении изображения через сеть Xception данные сначала проходят через поток ввода, затем через средний поток, который повторяется восемь раз, и, наконец, через выходной поток.

Сравнительное моделирование сетей на базе архитектуры SSD

Рассмотрим сравнительные результаты, полученные для различных базовых сетей модели SSD. Наибольшие значения метрик качества, полученные среди всех эпох обучения, для разработанных алгоритмов приведены в табл. 1.

Таблица 1

Результаты тестирования алгоритмов на основе модели SSD с использованием различных базовых сетей с оптимальными параметрами запуска

Базовые сети	loss	val_F1	val_ loss	val_ mAP	val_Pre-cision	val_ Re-call	last_ epoch
SSD300+ VGG16	3,081	0,842	4,209	0,771	0,842	0,842	30
SSD300+ VGG19	4,249	0,849	5,207	0,653	0,886	0,816	61
SSD300+ MobileNetV2	3,452	0,743	5,099	0,511	0,813	0,684	38
SSD300+ Xception	2,679	0,842	4,731	0,654	0,842	0,842	31

Согласно метрикам mAP и Recall лучшим подходом среди рассмотренных вариаций базовых сетей также является использование базовой сети Xception. Однако такой подход немного проигрывает по метрике Precision алгоритму SSD300 + VGG16.

Алгоритм на основе архитектуры EfficientDet

EfficientDet – семейство нейросетевых детекторов, предложенное в 2020 году в исследовании [18]. Общая архитектура EfficientDet в значительной степени соответствует парадигме одноступенчатых (one-stage) детекторов. За базовую часть данной сети берется сеть EfficientNetB0, предобученная на упоминавшейся выше базе изображений ImageNet. Далее к базовой сети присоединяется двунаправленная пирамида признаков (BiFPN – bi-directional feature pyramid network), идея создания которых появилась после изучения производительности и эффективности сетей для улучшения масштабирования, таких как FPN, PANet и NAS-FPN [21].

Сравнительные результаты работы нейросетевых алгоритмов

В табл. 2 приведены результаты для значений метрики точности (AP), вычисленной для различных классов, используемых в исследовании, при запуске рассмотренных выше нейронных сетей архитектуры SSD с оптимальными параметрами запуска и нейронной сети архитектуры EfficientDet, соответственно.

Таблица 2

Сравнение результатов работы нейросетевых алгоритмов по точности

Тип сети	AP («рак»)	AP («ранний рак»)	AP («иная патология»)
SSD300+VGG16	0,707	0,896	0,409
SSD300+VGG19	0,805	0,873	0,284
SSD300+MobileNetV2	0,625	0,625	0,282
SSD300+Xception	0,704	0,810	0,445
EfficientDet+EfficientNetB0	0,989	0,989	0,940

Как следует из приведенных результатов, лучшие результаты по метрике точности показала нейронная сеть EfficientDet. Для архитектуры SSD результаты по точности удается повысить при использовании базовой части VGG19.

Важным моментом для практической работы нейросетевых алгоритмов является обеспечение их устойчивости (робастности). Для тестирования по этому критерию был использован следующий подход. Нейросетевые модели обучались только на изображениях с эндоскопа OLYMPUS EXERA III GIF-HQ190, а тестирование проводилось только на выборке изображений с предыдущих моделей эндоскопов OLYMPUS 160, 170 и 180 серий. Результаты такого эксперимента приведены в табл. 3. В ячейках таблицы отражены результаты метрики точности и уровень этих показателей относительно результатов, приведенных в табл. 2.

Приведенные результаты показывают, что подход на базе нейронной сети EfficientDet остается наилучшим для такого «стресс-теста», хотя и показывает несколько более высокий уровень деградации результатов для классов «рак» и «ранний рак».

Таблица 3

Сравнение робастности нейросетевых алгоритмов

Тип сети	AP («рак»)	AP («ранний рак»)	AP («иная патология»)
SSD300+VGG16	0,644 91,1 %	0,824 92,0 %	0,351 85,8 %
SSD300+VGG19	0,722 89,7 %	0,786 90,0 %	0,239 84,2 %
SSD300+MobileNetV2	0,560 89,6 %	0,566 91,4 %	0,241 85,4 %
SSD300+Xception	0,628 89,2%	0,732 90,4%	0,361 81,1%
EfficientDet+EfficientNetB0	0,872 88,2 %	0,860 87,0 %	0,815 86,7 %

Другим важным параметром работы алгоритма детектирования патологий на эндоскопических изображениях является время обработки одного

кадра. Для подсчета данного значения был реализован программный эксперимент, осуществляющий тестирование алгоритмов на батчах, каждый из которых был составлен из 16 изображений из собранной базы эндоскопических снимков. Число итераций за этап тестирования по батчам равнялось 22. Для каждого из разработанных в рамках данной работы нейросетевых алгоритмов было получено общее время тестирования, затраченное на обработку батчей за 22 итерации. На основе полученного значения было рассчитано среднее время обработки одного кадра как отношение общего времени тестирования к произведению числа изображений в одном батче и числа итераций. Результаты эксперимента, полученные на производительном персональном компьютере типовой конфигурации приведены в табл. 4.

Учитывая приведенные значения, можно сделать вывод о том, что наилучшим подходом по скорости работы среди перечисленных моделей нейросетей можно считать модель SSD с базовой сетью Xception. Следует также заметить, что значения, приведенные в табл. 6 различаются с практической точки зрения незначительно.

Таблица 4

Сравнение нейросетевых алгоритмов по скорости работы

Тип сети	Общее время тестирования (число итераций за 1 с)	Среднее время обработки 1 кадра
SSD300+VGG16	13,566 с (1,6 итер/с)	0,039 с
SSD300+VGG19	13,485 с (1,61 итер/с)	0,038 с
SSD300+ MobileNetV2	13,727 с (1,620 итер/с)	0,039 с
SSD300+Xception	**12,644 с (1,74 итер/с)**	**0,036 с**
EfficientDet+ EfficientNetB0	17,720 с (1,24 итер/с)	0,050 с

Заключение

Для подведения итогов сравнительного тестирования врачи-эндоскописты ЯОКОБ в ходе экспертного обсуждения определили следующую практическую значимость рассмотренных выше критериев: точность алгоритма – 50 %, робастность алгоритма – 30 %, скорость работы – 20 %. Таким образом, многостороннее сравнительное тестирование нейросетевых алгоритмов с учетом мнения экспертов-эндоскопистов о практическом

вкладе того или иного критерия привело к выбору подхода на базе нейронной сети EfficientDet. Этот алгоритм далее был выбран, как основной для реализации нейросетевого модуля детектирования патологий на эндоскопических изображениях желудка.

Список литературы

1. Карпов О.Э., Храмов А.Е. Информационные технологии, вычислительные системы и искусственный интеллект в медицине. М.: ДПК Пресс. 2022. 480 с.

2. Николенко С.И., Кадурин А.А., Архангельская Е.О. Глубокое обучение. С-Пб.: Питер. 2018. 480 с.

3. Палевская С.А., Короткевич А.Г. Эндоскопия желудочно-кишечного тракта. М.: ГЭОТАР-Медиа. 2020. 752 с.

4. Munzer B., Schoeffmann K., Boszormenyi L. Content-based processing and analysis of endoscopic images and videos: A survey. Multimed. Tools Appl. (2018) 77. P. 1323–1362.

5. Кореневский Н.А., Охотников О.И., Белозеров В.А., Родионова С.Н. Нечеткие модели дифференциальной диагностики рака поджелудочной железы и хронического панкреатита по данным эндоскопической ультрасонографии // Медицинская техника. 2022. № 6. С. 37–39.

6. Куваев Р.О., Кашин С.В. Современное эндоскопическое исследование желудка с использованием методик узкоспектральной и увеличительной эндоскопии: техника проведения и алгоритмы диагностики // Доказательная гастроэнтерология. 2016. Т. 2. № 5. С. 3–13.

7. Хрящев В.В., Ганин А.Н., Лебедев А.А., Степанова О.А., Кашин С.В., Куваев Р.О. Разработка и анализ алгоритма детектирования патологий на эндоскопических изображениях желудка на основе сверточной нейронной сети // Цифровая обработка сигналов. 2018. № 3. С. 70–75.

8. Коваленко Д.А., Гнатюк В.С. Ассоциация сцен в эндоскопических видео // GraphiCon 2017: Обработка и анализ биомедицинских изображений. Пермь. 2017. С. 269–274.

9. Степанова О.А., Лебедев А.А., Хрящев В.В., Приоров А.Л. Использование сверточной нейронной сети SSD для детектирования патологий при эндоскопии желудка // Цифровая обработка сигналов и ее применение (DSPA-2019): докл. 21-й междунар. конф. Россия. М.: 2019. С. 533–537.

10. Куваев Р.О., Никонов Е.Л., Кашин С.В., Капранов В.А., Гвоздев А.А. Контроль качества эндоскопических исследований, перспективы автоматизированного анализа эндоскопических изображений // Кремлевская медицина. Клинический вестник. 2013. Т. 2. С. 51–56.

11. Андержанова А.С., Степанова О.А., Хрящев В.В., Волков Д.Б. Разработка нейросетевого алгоритма классификации патологий на эндоскопических видеоизображениях желудка // СПбНТОРЭС: труды ежегодной НТК. 2022. № 1 (77). С. 20–22.

12. Zheng S., Song Y., Leung T., Goodfellow I. Improving the Robustness of Deep Neural Networks via Stability Training // IEEE Conference on Computer Vision and Pattern Recognition (CVPR). 2016.

13. Simonyan K., Zisserman A. Very Deep Convolutional Networks for Large-Scale Image Recognition. CoRR, abs/1409.1556. 2015.

14. Review: MobileNetV2 – Light Weight Model (Image Classification). https://towardsdatascience.com/review-mobilenetv2-light-weight-model-image-classification-8febb490e.

15. Chollet F. Xception: Deep learning with depthwise separable convolutions // arXiv Preprint. 2017. P. 1610–2357.

16. Image Classification on ImageNet. https://paperswithcode.com/sota/image-classification-on-imagenet.

17. Keras: Deep Learning for humans. https://keras.io/.

18. Tan M., Pang R., Quoc V. Le EfficientDet: Scalable and Efficient Object Detection // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2020.

19. EfficientDet (Scalable and Efficient Object Detection) implementation in Keras and Tensorflow. https://github.com/xuannianz/EfficientDet.

20. The NVIDIA TAO Toolkit: EfficientDet. https://docs.nvidia.com/tao/tao-toolkit-archive/tao-30-2202/text/object_detection/efficientdet.html.

21. A BiFPN or Weighted Bi-directional Feature Pyramid Network. https://paperswithcode.com/method/bifpn.

ИМЕННОЙ УКАЗАТЕЛЬ АВТОРОВ

– B –

Brueva A., 202

– E –

Edeleva J., 202, 250
El-Khatib Samer, 54

– K –

Kushina N., 250

– M–

Meshcheryakova A.A., 250

– R –

Rodzin Sergey, 54

– S –

Shats V.N., 262
Skobtsov Yuri, 54
Smetanina O.A., 250

– А –

Антонов Д.И., 116
Антонов И.М., 337

– Б –

Базенков Н.И., 98
Бибиков Н.Г., 133
Болотникова А.А., 328
Брусиловский Л.И., 183
Брюховецкий А.С., 183
Бух А.В., 271

– В –

Вадивасова Т.Е., 271
Вечкапова С.О., 141, 166
Витюгова Ю.М., 44
Воронков Г.С., 149

– Г –

Гусева А.И., 292

– Д –

Дорогов А.Ю., 88

– Е –

Егоров Н.М., 159
Еремин Е.В., 241
Ефиторов А.О., 44

– И –

Илларионов Е.А., 361

– К –

Калинина А.Ю., 312
Карандашев Я.М., 370

Карташов С.И., 12
Киреев В.С., 292, 302, 312
Клиньшов В.В., 213, 283
Ковальчук А.В., 213, 241
Кожевников С.П., 353
Кожин С.П., 183
Козлов Д.С., 353
Козунов В.В., 192
Комышев Д.А., 353
Кононов Р.А., 222
Корнилов М.В., 159
Крылов А.К., 231
Кузьменко А.В., 302
Кулябина Е.В., 321
Кулябина Т.В., 321
Курьян В.Е., 78

– М –

Макаренко Н.Г., 12
Макаров М.В., 61
Масленников О.В., 222
Морозов В.Ю., 321
Морозова В.В., 321
Мосина Л.Е., 12
Мысин И.Е., 126

– Н –

Назарько М.Ю., 68
Новожилов К.А., 353

– П –

Парин С.Б., 241
Пермяков С.А., 241
Пиджакова Н.С., 61
Полевая С.А., 241
Проскура А.Л., 141, 166

– Р –

Ратушняк А.С., 141, 166
Рогачёв А.О., 175
Родионов Д.О., 36
Рыбалова Е.В., 271
Рыбинцев А.С., 12

– С –

Сайбодалов М.Х., 370
Самсонович А.В., 68
Семенов И.А., 61
Сергеев В.Г., 353
Соловьев И.А., 283
Сухов С.В., 116
Сысоев И.В., 159
Сысоева М.В., 159
Сысоева О.В., 175

– Т –

Таранин М.В., 106
Таранин С.В., 106

– У –

Ушаков В.Л., 12

– Ф –

Федоров К.А., 68
Федотчев А.И., 241

– Х –

Хрящев В.В., 380
Хусаинов Р.Р., 166

– Ч –

Чаплинская Н.В., 98
Чернышев Л.С., 337

– Ш –

Шамарина Е.А., 292
Шепелев И.А., 271
Шибзухов З.М., 27
Широкий В.Р., 44
Шлапак Н.П., 274, 328