

Нейроинформатика, её приложения и анализ данных

XXXI Всероссийский семинар

**Красноярск
2023**

Министерство науки и высшего образования РФ
Сибирское отделение РАН
Российская ассоциация нейроинформатики
Институт вычислительного моделирования СО РАН

НЕЙРОИНФОРМАТИКА, ЕЁ ПРИЛОЖЕНИЯ И АНАЛИЗ ДАННЫХ

МАТЕРИАЛЫ
ТРИДЦАТЬ ПЕРВОГО ВСЕРОССИЙСКОГО СЕМИНАРА
29 сентября 2023 года

Красноярск 2023

УДК 007.52 (042.3)

Н 43

Нейроинформатика, её приложения и анализ данных: Материалы XXXI Всероссийского семинара, 29 сентября 2023 года / Под ред. М.Г. Садовского, отв. за вып. М.Ю. Сенашова; – Красноярск: Институт вычислительного моделирования СО РАН, 2023. – 148 с.

В сборнике представлены материалы XXXI Всероссийского семинара «Нейроинформатика, её приложения и анализ данных», проходившей в городе Красноярске 29 сентября 2023 года.

Основной задачей конференции является всесторонний и высоко квалифицированный обмен новейшими достижениями в различных областях нейроинформатики (как теории нейросетей, так и в области различных практических приложений), а также в области нелинейного статистического анализа многомерных данных, обладающих нетривиальными структурами.

Большое внимание уделено анализу областей применимости и точности методов обработки многомерных данных, анализу устойчивости различных новых (нелинейных) методов кластеризации, разбор большого числа конкретных случаев, иллюстрирующих эти проблемы и достижения.

Материалы предназначены для научных работников, преподавателей, студентов и аспирантов соответствующих специальностей.

Конференция проводится при поддержке Красноярского математического центра, финансируемого Минобрнауки РФ в рамках мероприятий по созданию и развитию региональных НОМЦ (Соглашение № 075-02-2023-912).

Редакционная коллегия:

Садовский Михаил Георгиевич – ответственный редактор

Сенашова Мария Юрьевна – ответственный за выпуск

© ИВМ СО РАН, 2023

© Коллектив авторов, 2023

ISBN 978-5-6047078-3-8



9 785604 707838

МОНИТОРИНГ СОБЫТИЙ ВЗВЕШИВАНИЯ ТРАНСПОРТА НА АВТОМОБИЛЬНОЙ ВЕСОВОЙ С ПРИМЕНЕНИЕМ ИНСТРУМЕНТОВ КОМПЬЮТЕРНОГО ЗРЕНИЯ

А.Е. Алехина^{1,2}, Толмачев Е. В., М.Г. Дорпер¹

¹ Сибирский государственный университет науки и технологий
им. М.Ф. Решетнева, , a.tolmacheva@solutionfactory.com

² Сибирский федеральный университет,

Аннотация

В работе описано решение задачи автоматической фиксации факта взвешивания грузовых автомобилей на основании видеопотока камеры наблюдения за весовой в зоне погрузки-выгрузки. Задача решалась с применением комбинации методов разности кадров для детекции движения, модели YOLOv7 для детекции интересующих объектов типа «грузовик» и «колесо» и перцептивных хэшей рHASH для исключения повторной детекции одного и того же события. Предложенное решение показало удовлетворительную точность и пригодность для практического применения для автоматизации контроля процесса взвешивания грузовых автомобилей.

Ключевые слова: мониторинг транспорта, компьютерное зрение, YOLOv7, рHASH

Введение

Применение инструментов компьютерного зрения для решения учетных задач в ходе управления предприятием получило в настоящее время широкое распространение. Следует также отметить важную роль в интеллектуальном транспорте и интеллектуальном обнаружении дорожных событий такой задачи, как обнаружение и отслеживание транспортных средств в видеопотоке камер наружного наблюдения. Обусловлено это требованиями снижения себестоимости учетных и контрольных операций и исключения из их выполнения субъективного фактора, влияния уровня квалификации и дисциплины человека-наблюдателя.

В данной работе будет рассмотрено решение частной задачи мониторинга

производственной площадки – отслеживание процесса взвешивания грузовых автомобилей на весовой для учета массы груза при погрузочно-разгрузочных операциях.

Связанные работы

Вопрос применения инструментов компьютерного зрения к задачам обнаружения, классификации и отслеживания транспортных средств в настоящее время рассматривается в большом количестве научных исследований. Подробный обзор применения систем искусственного зрения в задачах управления транспортом приведен в работе [1]. В работе [2] рассматривается решение задачи обнаружения и отслеживания транспортных средств на основе компьютерного зрения для сценариев в реальном времени на основе метода HOG для извлечения признаков, импровизированного корреляционного фильтра для отслеживания, и модели AdaBoost для классификации объектов. Авторы статьи [3] для управления колесными роботами используют алгоритм обнаружения объектов, основанный на сочетании архитектур YOLO и GhostNet. Работа [4] описывает применение нового подхода на базе сверточных нейронных сетей к решению задачи создания аппаратно-эффективной автоматизированной системы распознавания номерных знаков для ограниченной среды с ограниченными ресурсами. Работа [5] описывает сверточную нейронную сеть Vision Transformer Particle Region (VitP-RCNN), обеспечивающую ускорение извлечения признаков для задачи визуального управления посадкой беспилотных летательных аппаратов.

Авторы данной работы также исследовали возможности решения задач мониторинга производственных площадок и отслеживания транспортных средств с помощью инструментов компьютерного зрения в своих работах [6], [7] и [8].

Таким образом, решение поставленной в работе задачи – отслеживание прохождения грузовых автомобилей процедуры взвешивания при помощи инструментов компьютерного зрения – важно для производства и актуально с точки зрения применяющихся инструментов.

Экспериментальные материалы

В качестве исходной информации использовались записи видеопотока с камеры видеонаблюдения службы безопасности весовой предприятия. Исходное изображение получаемое с камеры имеет разрешение 1920x1080 пикселей RGB формата.

При подготовке обучающей выборки вручную было размечено 2675 изображений размером 1920x1080, при этом были выделены объекты классов «грузовик» (truck) и «колесо» (sheel).

Таблица 1. Структура обучающей выборки для детектора класса грузовик и шины

Название класса	Количество изображений	Количество образцов	Выборка изображений		Выборка образцов	
			train	test	train	test
Грузовик (Truck)	2675	2590	1873	802	1813	777
Колеса (Wheel)		4937			3456	1481

Как видно из таблицы 1, выборка не сбалансирована по количеству экземпляров каждого класса, класс «колесо» по количеству образцов представлен больше, чем класс «грузовик». Однако даже до обучения модели было понятно, что это не должно снизить точность определения, так как структура образцов сильно отличается друг от друга.

Методы решения задачи

Для создания телеметрии производился круглосуточный сбор видеопотока с весовой, данные компоновались в видеоролики длительностью в 1 минуту. Роликам присваивалось название, сформированное из времени записи ролика в формате представления времени в ОС Unix.

Система отслеживала наличие движения во всем кадре методом вычитания кадров [9]. В случае, если обнаружено движение в кадре, то далее к обработке видеопотока применяется архитектура YOLO [10], обрабатывающая каждый кадр полностью.

В случае, если модель YOLO обнаружила знакомые ей объекты и определила класс «truck», то проверяется условие, находится ли грузовик в зоне интереса (зона интереса выделена синей линией).

Если грузовик находится в зоне интереса, то происходит проверка на наличие в зоне интереса объектов класса «колесо» (wheel). Зона интереса для поиска колес выделена красной линией. Если колеса обнаружены, то система фиксирует факт события корректного взвешивания. Зоны интереса, выделенные на кадре камеры видеонаблюдения, показаны на рис. 1.

Следует отметить, что по результатам сбора первоначальной базы данных было обнаружено большое количество ложно-положительных срабатываний, например один и тот же грузовик может заезжать на зону взвешивания несколько раз. Для того, чтобы очистить полученный протокол и повысить точность определения событий взвешивания был применен подход, включающий выделение хэшей и очистка протоколов от ложно-положительных событий. Для этого система, фильтруя полученную телеметрию, формирует перцептивный хэш [11] по каждому событию. Далее производится просмотр полученных значений хэша в интервале времени одна минута, при этом для поиска одинаковых хэшей и исключения задвоения система выбирает как базовое событие первое событие в протоколе из пары событий с одинаковыми значениями рHASH.

Промежуток анализа на задвоение установлен в размере десяти минут. В выбранном промежутке смотрятся дубли хэшей, если в событии не присутствует дубль хэша, то система идентифицирует наступление следующего базового события.

Результаты

По результатам обучения на собранном датасете метрика точности показа-

ла высокие показатели общей точности (precision), что позволяет использовать модель на данном типе сцен для дальнейшей работы. В таблице 2 указаны значения метрик, полученные по результатам тестирования обученной системы.

На рис. 2 продемонстрирована детекция классов «грузовик» и «колесо» обученной моделью YOLOv7 на кадре видеопотока с камеры наблюдения.

Таблица 2. Метрики точности полученной в ходе работы модели YOLOv7

Name class	Average precision %	Recall	f1-score	IoU%	mAP%
Truck	96.71	0.89	0.88	73.18	89.92
Wheel	96.90				

После применения детектора формируется хэш изображения для решения задачи поиска одинаковых образцов.




Рис. 1. Сцена, на которой проходит тестирование алгоритма. Синяя граница рамки - зона интереса для детектирования центра транспорта, красная граница рамки - зона интереса для детекции и подсчета количества колес выезжающего транспорта на платформу.



Рис. 2. Пример работы детекции объектов на изображении с помощью модели YOLO

На рис. 3 показан список сформированных хэшей. Название файла соответствует названию видеофрагмента, из которого было получено соответствующее значение хэша.

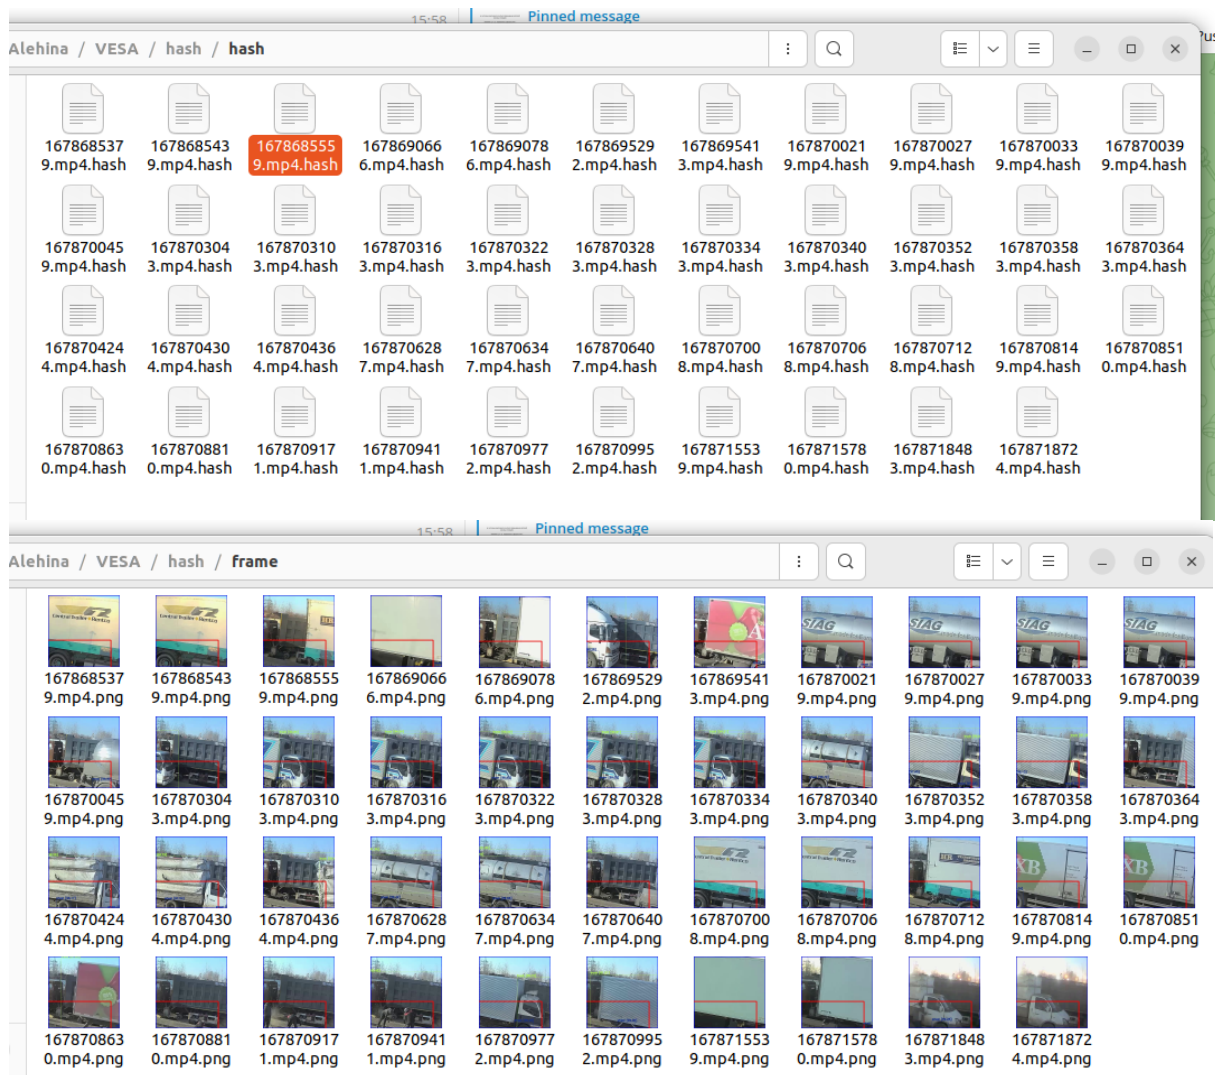


Рис. 3. Формирование списка хэшей на тестовом ролике

В результате обработки телеметрии система формирует журнал событий (рис. 4), в котором отображается время детекции объекта в зоне интереса, хэш объекта (числовое значение в скобках) и описание обнаруженных случаев задвоения детектируемых событий. Процесс формирования хэша системой показан на рис. 5.

```
Открыть [+] log.txt ~/Рабочий стол/doc С
1 Cora search hash begin
2
3 Событие 2022-11-28 08:39:36 (1669599576)
4 для события 2022-11-28 08:39:36 обнаружен дубль в 2022-11-28 08:42:36 (1669599756)
5
6 Событие 2022-11-28 08:42:36 (1669599756)
7
8 Событие 2022-11-28 10:49:43 (1669607383)
9
10 Событие 2022-11-28 10:52:43 (1669607563)
11
12 Событие 2022-11-28 10:58:43 (1669607923)
13
14 Событие 2022-11-28 11:16:44 (1669609004)
15
16 Событие 2022-11-28 11:26:45 (1669609605)
17
18 Событие 2022-11-28 11:50:46 (1669611046)
19 для события 2022-11-28 11:50:46 обнаружен дубль в 2022-11-28 11:53:46 (1669611226)
20
21 Событие 2022-11-28 11:53:46 (1669611226)
22
23 Событие 2022-11-28 12:03:47 (1669611827)
24
25 Событие 2022-11-28 13:05:50 (1669615550)
--
```

Рис. 4. Фрагмент логирования событий с поиском дубликата

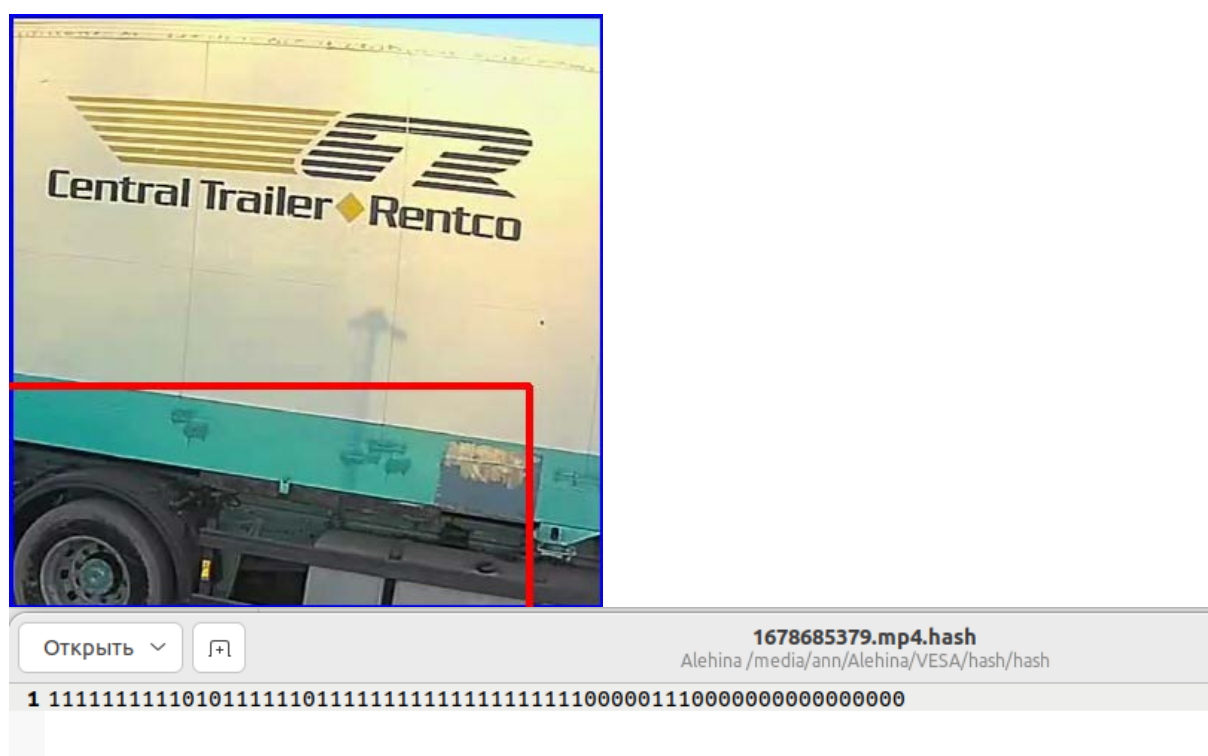


Рис. 5. Пример полученного хэша для фрагмента изображения

После применения фильтра отсортировки одних и тех же объектов, из

телеметрии ушли 3 дублирующих событий, где одна машина встала на весы только с третьего раза, другая машина встала с другой стороны весов, третья машина поместилась на весовую платформу со второго раза.

Вывод

Таким образом, поставленная задача – надежная детекция событий взвешивания грузовых автомобилей на весовой предприятия – была успешно решена. Успех обеспечило совместно применение таких методов и алгоритмов, как:

- метод оценки разности кадров для детекции движения;
- модель YOLOv7 для детекции интересующих объектов (грузовик, колесо);
- метод расчета и сравнения перцептивных хэшей rHASH для устранения дублирования детекции одного и того же события (например, многократный заход в зону интереса одного и того же грузовика)

Список литературы

1. Postolit A. V. Prospects for the Use of Artificial Intelligence and Computer Vision in Transport Systems and Connected Cars // *World Transp. Transp.* 2021. Vol. 19, № 1. P. 74–90.
2. Senthil Murugan A. et al. Computer Vision-Based Vehicle Detection and Tracking. 2021. P. 2899–2906.
3. Hu Y. et al. Object Detection Algorithm for Wheeled Mobile Robot Based on an Improved YOLOv4 // *Appl. Sci.* 2022. Vol. 12, № 9. P. 4769.
4. Padmasiri H. et al. Automated License Plate Recognition for Resource-Constrained Environments // *Sensors.* 2022. Vol. 22, № 4. P. 1434.
5. Yuan B., Ma W., Wang F. High Speed Safe Autonomous Landing Marker Tracking of Fixed Wing Drone Based on Deep Learning // *IEEE Access.* 2022. Vol. 10. P. 80415–80436.
6. Alekhina A., Gurenko A., Dorrer M. Application of Computer Vision Tools to Create a System for Monitoring the Work of Ground Equipment in Open Pits of

- Gold Mining Enterprises. 2022. P. 203–218.
7. Dorrer M.G., Tolmacheva A.E. Comparison of the YOLOv3 and Mask R-CNN architectures' efficiency in the smart refrigerator's computer vision // J. Phys. Conf. Ser. 2020. Vol. 1679. P. 042022.
 8. Dorrer M.G., Popov A.A., Tolmacheva A.E. Building an artificial vision system of an agricultural robot based on the DarkNet system // IOP Conf. Ser. Earth Environ. Sci. 2020. Vol. 548. P. 032032.
 9. Chate M., Amudha S., Gohokar V. V. Object Detection and tracking in Video Sequences. 2012.
 10. Bochkovskiy A., Wang C.-Y., Liao H.-Y.M. YOLOv4: Optimal Speed and Accuracy of Object Detection. 2020.
 11. Buldas A., Kroonmaa A., Laanoja R. Keyless Signatures' Infrastructure: How to Build Global Distributed Hash-Trees. 2013. P. 313–320.
 12. Roy P. et al. Adaptive thresholding: A comparative study // 2014 International Conference on Control, Instrumentation, Communication and Computational Technologies (ICCICCT). IEEE, 2014. P. 1182–1186.
 13. Ronneberger O., Fischer P., Brox T. U-Net: Convolutional Networks for Biomedical Image Segmentation. 2015.
 14. Wang Y. et al. An improved Deeplabv3+ semantic segmentation algorithm with multiple loss constraints // PLoS One / ed. Zhang Q. 2022. Vol. 17, № 1. P. e0261582.
 15. Dice L.R. Measures of the Amount of Ecologic Association Between Species // Ecology. 1945. Vol. 26, № 3. P. 297–302.

СПОСОБНОСТЬ УПРАВЛЕНИЯ СОСТОЯНИЕМ ОРГАНИЗМА МУЖЧИН И ЖЕНЩИН

Н.М. Богатов, А.Н. Богатова, С.А. Сухих

Кубанский государственный университет, *bogatov@phys.kubsu.ru*

Введение

Человек в современном обществе находится в условиях высокого ритма жизни, который способствует диффузному распространению тревоги, стресса, фрустраций и других факторов, нарушающих психологическое здоровье. При этом человек не получает достаточной социальной поддержки и нуждается в поисках способов самосохранения.

Многовековая практика показала, что возможно решить проблемы дисфункции организма. В работах [1, 2] развивается концепция, согласно которой воздействие сознания субъекта изменяет энергоинформационный обмен в организме, отражающийся в функционировании его органов и систем. Обсудим условия успеха использования техник и методов саморегуляции.

В работе проведено исследование влияния психологических особенностей субъектов психофизиологической саморегуляции на динамику функциональных состояний их организма. Методологической основой проведенного исследования выступает положение, согласно которого, категория субъекта определяется в большей степени уровнем эволюции сознания. Сознание субъекта отличает рефлексивность, т.е. способность субъекта интерпретировать мир с различных углов видения. Это предполагает большую осознанность происходящих событий, как во внутреннем, так и внешнем пространствах человека. В этой интерпретации уместно говорить о субъектности как мере осознанности тех или иных аспектов бытия человека [3].

Активность как один из атрибутов субъекта может иметь разные формы проявления, такие как внешне материально-преобразующую деятельность. При этом субъект учитывает последствия совершаемых им деяний, распределенных во времени. Активность также может иметь пассивную форму реализации, связанную с созерцательно-рефлексивными действиями субъекта. Изменения как

следствие этой активности происходят во внутреннем пространстве субъекта. Отсюда вытекает гипотеза исследования, согласно которой успешность саморегулятивной активности связана с мерой субъектности в человеке. Такой подход не противоречит деятельностной теории сознания [4].

Цель исследования – определение влияния меры субъектности на способность к саморегуляции с учетом гендерных различий.

Объект исследования – субъекты учебной деятельности, работающие по программе психофизической саморегуляции.

Предмет исследования – процесс влияния состояния сознания на успешность овладения техникой саморегуляции.

Методика исследований

В исследовании приняли участие 25 человек в возрасте от 20 до 23 лет, 14 мужчин, 11 женщин. Все участники исследования были проинформированы о его цели и проинструктированы о методиках тестирования. Методика исследования включала шесть этапов: 1 – предварительное измерение (определение начального функционального и психоэмоционального состояния испытуемых с помощью аппаратно-программного диагностического комплекса (АПДК) Silver Step Pulse); 2 – стимуляцию (методически организованный сеанс саморегуляции); 3 – определение функционального и психоэмоционального состояния испытуемых после сеанса саморегуляции; 4 – психологическое тестирование; 5 – обработку результатов измерений, полученных с помощью Silver Step Pulse; 6 – анализ результатов исследований. Длительность сеансов саморегуляции составляла 20 ÷ 30 минут. Применялись следующие психотехники, использующие концентрацию сознания и дыхание: абдоминальное дыхание, работа со вторым энергоцентром, работа с семью энергоцентрами, кокон, дыхание в мозг и другие.

Для объективных измерений динамики состояний: вегетативной нервной системы, нейрогуморальной регуляции, психоэмоционального состояния и спектрограммы головного мозга и других показателей использовался метод кардиоинтервалографии (КИГ), реализованный в АПДК Silver Step Pulse. В результате обработки кардиоинтервалов с помощью гистографического анализа вычисляет-

ся мода распределения, ее амплитуда и вариационный размах. На основании этих параметров вычисляется интегральный показатель – индекс напряжения (ИН). Индекс напряжения пропорционален средней частоте сердечных сокращений и обратно пропорционален диапазону, в котором варьирует интервал между двумя ударами сердца и отражает степень вовлеченности организма в стресс.

В норме в спокойном состоянии сердечный ритм преимущественно регулируется собственным водителем ритма и теми местными влияниями, которые поступают от симпатических и парасимпатических ганглиев, а также уровнем некоторых гормонов в крови (например, адреналина). При этом частота сердечного ритма волнообразно меняется, разброс времени между отдельными сердечными ударами достаточно велик, индекс напряжения низкий (не превышает 100 у. е.).

При состояниях, требующих повышенной готовности, быстроты реакции, при стрессе и некоторых патологических состояниях к регуляции сердечного ритма, подключаются более высокоорганизованные структуры мозга – ствол и кора головного мозга. Ритм становится более правильным, время между ударами одинаковым, – это так называемый «жесткий ритм». При этом индекс напряжения сильно увеличивается.

При патологических состояниях со стороны сердца (стенокардия, ишемическая болезнь сердца) индекс напряжения также увеличивается, и при высоком риске возникновения инфаркта миокарда может превышать 500–600 у. е. У людей со здоровой сердечно – сосудистой системой, на фоне стресса, повышенного внимания, готовности, этот показатель повышается иногда до 200–300 у. е., причем, чем выше этот показатель, тем сильнее уровень стресса.

Таким образом, сердечный ритм является реакцией организма на различные раздражения внешней и внутренней среды. Частота сердечных сокращений является интегрированным показателем взаимодействия трех регулирующих сердечный ритм факторов: рефлекторного симпатического, рефлекторного парасимпатического и гуморального. Изменение ритма сердца является универсальной оперативной реакцией целостного организма в ответ на влияние.

Для определения меры субъектности в качестве методического инструмен-

тария в работе использовались опросник Кейрси и опросник «Диагностика субъектности» Е.Н. Волковой. Опросник Кейрси содержит четыре биполярные шкалы, отображающие содержание восьми психологических факторов темперамента:

1. Шкала Е-І – ориентация сознания: Е (экстраверсия) – ориентация сознания наружу, на объекты, І интроверсия) – ориентация сознания внутрь, на субъекта;
2. Шкала S-N – способ ориентировки в ситуации: S (здравый смысл) – ориентировка на конкретную информацию, N (интуиция) – ориентировка на обобщённую информацию;
3. Шкала Т-F – основа принятия решений: Т (мышление) – рациональное взвешивание альтернатив; F (чувство) – принятие решений на эмоциональной основе;
4. Шкала J-P – способ подготовки решений: J (суждение) – предпочтение планировать и заранее упорядочивать информацию, P (восприятие) – предпочтение действовать без детальной предварительной подготовки, больше ориентируясь по обстоятельствам.

В тесте «Диагностика субъектности» Е.Н. Волковой используются 6 шкал: осознанная активность, способность к рефлексии, свобода выбора и ответственность за него, осознание собственной уникальности, понимание и принятие других, саморазвитие.

Экспериментальные данные обрабатывались с помощью табличного процессора Microsoft Excel.

Результаты исследований

Из всех показателей функционального состояния организма, определяемых АПДК Silver Step Pulse, выбраны показатели активности мозга (дельта-, тета-, альфа-, бета-, гамма-ритмов) и функционального состояния (индексы адаптации, напряженности, вегетативного равновесия, ресурсов организма, энергетического баланса, психоэмоционального состояния, гармонизации биоритмов, вегетативной регуляции, нейрогуморальной регуляции, комплексный показатель здоровья).

Изменение состояния респондентов определялось по изменению показателей активности мозга и функционального состояния в результате сеансов саморегуляции. Наличие механизмов саморегуляции организма должно приводить к каким-либо закономерностям во взаимном изменении этих показателей. Поэтому для данных каждого респондента рассчитывались коэффициенты корреляции для каждой пары показателей, из которых один или оба характеризуют активность мозга. Коэффициент корреляции считался значимым, если модуль его значение не менее 0,6. Для каждого респондента с номером k определялось число значимых корреляций m_k . Считаем, что значение m_k характеризует успешность процессов саморегуляции каждого субъекта и, таким образом, является объективной оценкой достигнутого результата.

Характеристику меры субъектности получим, анализируя связь между объективными результатами саморегуляции и результатами психологического тестирования. Обозначим результаты тестирования респондента с номером k по каждой из шкал: экстраверсия – e_k , интроверсия – i_k , здравый смысл – s_k , интуиция – n_k , мышление – t_k , чувство – f_k , суждение – j_k , восприятие – p_k , осознанная активность – a_k , способность к рефлексии – r_k , свобода выбора и ответственность за него – c_k , осознание собственной уникальности – u_k , понимание и принятие других – b_k , саморазвитие – d_k .

Отдельно для мужчин и женщин определялась возможная зависимость между числом значимых корреляций и значениями параметров для каждой шкалы. Отметим, что без гендерного разделения все зависимости имеют случайный характер. В результате выделены зависимости, имеющие ненулевой наклон линии тренда: для мужчин – $m_k(n_k)$, $m_k(t_k)$, $m_k(a_k)$, $m_k(r_k)$, $m_k(c_k)$, где $k = 1, 2, \dots, 14$, для женщин – $m_k(e_k)$, $m_k(a_k)$, $m_k(c_k)$, $m_k(b_k)$, $m_k(d_k)$, где $k = 1, 2, \dots, 11$.

Определим меру субъектности, используя выделенные шкалы:

для мужчин $ms_k = n_k + t_k + a_k - r_k + c_k, \quad k = 1, 2, \dots, 14,$

для женщин $ws_k = e_k - a_k + c_k + b_k + d_k, \quad k = 1, 2, \dots, 11.$

Знак, с которым шкала дает вклад в меру субъектности, определяется знаком тангенса угла наклона линии тренда.

На Рис.1, Рис.2 продемонстрированы зависимости между числом значи-

мых корреляций и мерой субъектности: точки имеют координаты (ms_k, m_k) , $k = 1, 2, \dots, 14$ для мужчин, (ws_k, m_k) , $k = 1, 2, \dots, 11$ для женщин. Линия тренда (показана пунктиром) имеет положительный коэффициент наклона. Коэффициент корреляции между параметрами (ms, m) равен 0,71 у мужчин, между параметрами (ws, m) равен 0,72 у женщин.




Рис.1. Влияния меры субъектности на способность к саморегуляции у мужчин.




Рис.2. Влияния меры субъектности на способность к саморегуляции у женщин.

Статистический разброс параметров, характеризующих способность к саморегуляции и меру субъектности, закономерен, так как человек – сложный многофакторный объект. Однако наличие линии тренда, имеющей положительное значение тангенса угла наклона, и достаточно высокое значение коэффициента корреляции между этими параметрами позволяют с оптимизмом смотреть на полученные результаты.

Заключение

Саморегуляция как методика управления своим психофизиологическим состоянием может достигаться посредством воздействия индивида на самого себя при помощи слов - аффирмаций, мыслеобразов, регулирования мышечного тонуса и дыхания. В процессе сеансов саморегуляции происходят целенаправленные трансформации отдельных функций психики и нервно-психических реакций. Эти процессы реализуются через специфические взаимодействия подкорковых и префронтальных отделов коры головного мозга, что направляет деятельность организма на решение функциональных задач. Результатами саморегуляции являются устранение эмоционального напряжения, снятие утомления, активизация способностей и другие эффекты.

Полученные результаты показывают, что существует связь между способностью к саморегуляции и психологическим типом личности. Для оценки результатов саморегуляции предлагается число значимых значений коэффициентов корреляции между физиологическими и психофизиологическими показателями, изменяющимися в результате осознанной деятельности субъекта с мысленными образами во внутреннем пространстве. На основе результатов тестирования, использующих опросники Кейрси и «Диагностика субъектности» Е.Н. Волковой, построены показатели меры субъектности, различные для мужчин и женщин. Способность к саморегуляции возрастает с увеличением меры субъектности приблизительно линейно.

У мужчин и женщин достаточно большой вклад в число значимых коэф-

фициентов корреляции дают пары с участием показателя дельта-ритма. Для большинства таких пар значение коэффициента корреляции отрицательно. Снижение дельта-активности мозга на фоне возрастающей активности альфа-ритма подтверждает осознанность процесса саморегуляции, так как дельта-ритм возникает при глубоком сне, а усиление интенсивности альфа-волн означает, что в психике запускаются оздоровительные и очищающие процессы, просыпаются скрытые ресурсы, оживает интуиция, повышается концентрация внимания [5].

Список литературы

1. Богатов Н.М. Влияние психотехник на изменение ритмов мозга и температуры лица / Н.М. Богатов, А.Н. Богатова, С.А. Сухих и др. // Нейроинформатика, её приложения и анализ данных: Материалы XXIX Всероссийского семинара, 24 сентября – 26 сентября 2021 г. Красноярск. Красноярск: Институт вычислительного моделирования СО РАН. — 2021. — С. 36 – 41.
2. Сухих С.А. Условия успеха саморегулятивной практики / С.А. Сухих, Н.М. Богатов, А.Н. Богатова // Приверженность вопросам психического здоровья: материалы III Международной научно-практической конференции. Москва, РУДН, 5–7 октября 2022 г. / под ред. О.Б. Михайловой, Е.Б. Башкина. – Москва: РУДН. — 2022. — С. 103 – 109.
3. Каленов А.А. К вопросу понимания субъектности и ее структуры в научных исследованиях / А.А. Каленов // Образование и воспитание. — 2017. — № 1(11) . — С. 3 – 6.
4. Серкин В.П. Деятельностная теория сознания (сознание как атрибут системы деятельностей субъекта) / В.П. Серкин // Психология. Журнал Высшей школы экономики. — 2015. — Т. 12. — №. 2. — С. 93 – 111.
5. Основные ритмы мозга и их измерение E-print: <http://neuroforsage.ru/brain-rithm/>

ПРИМЕНЕНИЕ ГЛУБОКИХ НЕЙРОННЫХ СЕТЕЙ ДЛЯ ПОВЫШЕНИЯ КАЧЕСТВА ОБНАРУЖЕНИЯ ДВУМЕРНЫХ МАТРИЧНЫХ ШТРИХ-КОДОВ В СИСТЕМАХ ВИДЕОАНАЛИТИКИ

А.Д.Богдашевская^{1,2}, А.В.Бахшиев^{1,2}

¹ Санкт-Петербургский политехнический университет Петра Великого,

bakhshiev_av@spbstu.ru

² ООО Системы Компьютерного Зрения

Введение

Для повышения скорости и эффективности, а также снижения стоимости при производстве компании используют AIDC (автоматическую идентификацию и сбор данных). Широкое распространение получили Data Matrix (DM) коды, которые хранят в себе закодированные текстовые данные. Их используют для идентификации продукции, контроля потока объектов, сортировки и автоматизированной обработки.

На данный момент разработано большое количество технологий определения DM-кодов на изображении [1]. Обычно, при необходимости декодирования кодов именно по изображению с камеры, большое внимание уделяется специфике выбора и монтажа источников освещения и камеры, поскольку это существенным образом влияет на надежность работы алгоритмов. Однако зачастую необходимо обеспечить простоту развертывания системы; также на этапе разработки может быть недостаточно данных об объекте эксплуатации. При этом потенциально могут возникнуть сложности при определении кодов на кадрах по причине неоднородного фона, наличия посторонних предметов с регулярными текстурами, слабого или неравномерного освещения, неудачного расположения кодов в поле зрения камеры. В этих случаях представляется целесообразным включить в алгоритм возможность применения алгоритмов обнаружения объектов общего назначения для того, чтобы облегчить первый шаг решения задачи, а именно – локализации положения кодов на изображении.

В первом разделе статьи приводится краткий обзор современных алгоритмов обнаружения DM-кодов, во втором разделе предлагается комбинированный

алгоритм, в третьем разделе описан датасет, в четвертом - приведены результаты экспериментального исследования предложенного алгоритма.

1. Алгоритмы обнаружения и декодирования DM-кодов

Для обнаружения DM-кодов разработано множество алгоритмов, которые можно разделить на 2 группы:

- Методы, основанные на нахождении Finder Pattern в виде знака “L”. В этом алгоритме используются следующие техники: edge detection (детектор границ Кэнни) [2] или adaptive thresholding (адаптивный подход к расчету порога яркости пикселя) [3].
- Методы, основанные на определении кода полностью за счет его необычной клетчатой структуры. Эти методы применяют SVM (метод опорных векторов) [4] и CNN (сверточные нейронные сети). Преимуществом методов данной группы в сравнении с предыдущей является то, что их можно успешно применять при поврежденном Finder Pattern или при нарушении Quite Zone.

Существуют программные пакеты, которые не только локализуют, но и декодируют DM-коды. К ним можно отнести Dynamsoft Barcode Reader (DBR) [5], Libdmtx [6], Google ML Kit [7], Apple Vision Framework [8], Zxing CPPc [9].

Из вышеперечисленных программных пакетов наибольшую точность показывает DBR при относительно высокой скорости работы [10]. Вторым по точности декодирования является Libdmtx, однако он затрачивает время в разы большее, чем остальные программные пакеты.

Специализированные алгоритмы показывают лучшие результаты по декодированию DM-кодов, если предварительно локализовать коды на изображении.

Для обнаружения объектов среди нейросетевых методов наибольшее распространение приобрели region proposal networks, представленные на данный момент Faster R-CNN [11] и архитектурами детекторов объектов «с одним проходом» (Single Shot Detector): Single Shot Multibox Detector (SSD) [12] and You Only Look Once (YOLO) [13].

В работе [14] проводится выбор лучшей архитектуры для обнаружения двумерных матричных кодов. R-CNN дает более точные результаты в силу более сложных вычислений, с другой стороны, это делает этот метод более времязатратным. Наилучшее соотношение затраченного времени и качества детекции показывают сети семейства YOLO.

2. Комбинированный алгоритм обнаружения и декодирования ДМ-кодов

В качестве модуля декодирования двумерных матричных штрих-кодов был выбран Libdmtx [6], который является наиболее точным открытым (open-source) программным пакетом. Для увеличения скорости декодирования и качества обнаружения кодов использовалась нейронная сеть YOLOv8, которая выделяет область интереса и передает декодеру только ее. Были рассмотрены четыре алгоритма (Рис. 1):

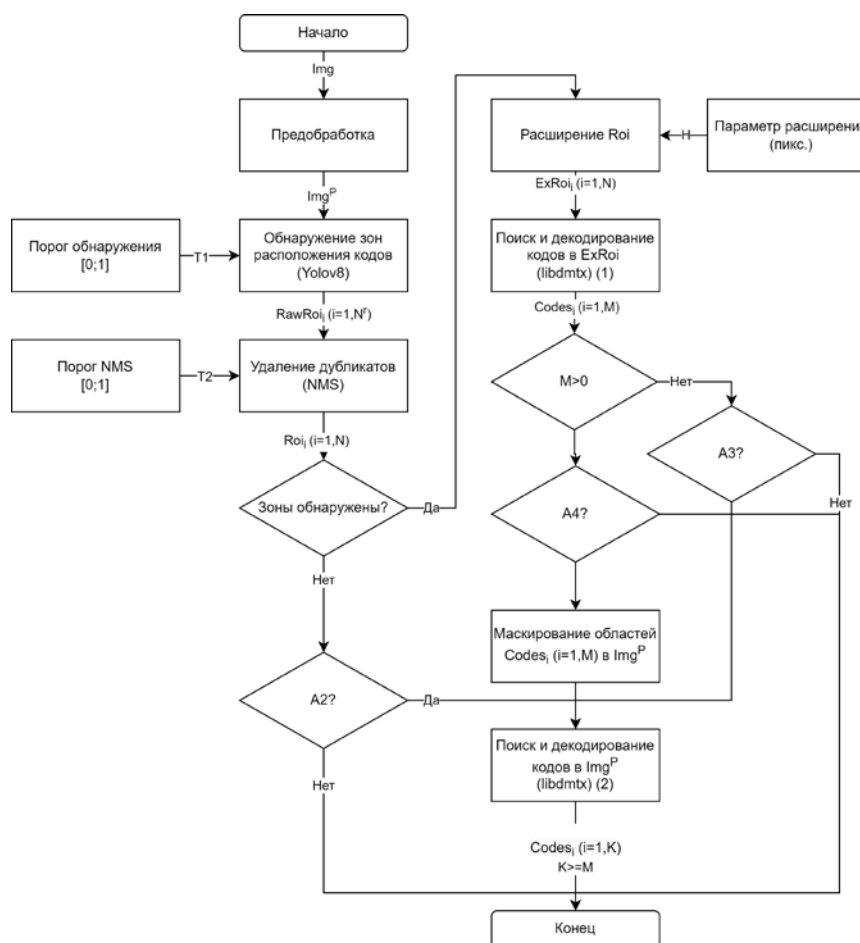


Рис. 1 – Пайплайн процесса дешифровки.

- A1-RoiOnly: ридеру передаются только области интереса, выбранные нейронной сетью
- A2-FullNetFail: ридеру передаются области интереса, выбранные нейронной сетью; если нейронная сеть не обнаружила коды на изображении, оно передается ридеру полностью
- A3-FullDecFail: ридеру передаются области интереса, выбранные нейронной сетью; если ни один код не был дешифрован, изображение передается ридеру полностью
- A4-FullMasked: ридеру передаются области интереса, выбранные нейронной сетью; после изображения передается ридеру полностью с маскированными дешифрованными кодами

Как референсный алгоритм был рассмотрен алгоритм A0-DmtxOnly, в котором полное изображение передавалось ридеру без использования нейронной сети.

3. Датасет и параметры обучения

Изначально было получено 519 фотографий с крышками и 75 фотографий с элементами ламп, на которые нанесены DM-коды. Датасет был расширен дополнительными и сгенерированными на основе существующих данных изображениями. Имеющиеся кадры были подвергнуты аугментации. Подробное описание датасета представлено в табл. 1.

Таблица 1

Описание наборов данных

Имя	Тип	Количество	Описание
D1-Orig	Исходные кадры с крышками	519	Крышки по одной штуке (Рис. 2а), в наборах по 6/12 штук (Рис. 2b), крышки на бутылках на конвейере (Рис. 2с) Минусы: вид только сверху
D1-CL	Исходные кадры с элементами ламп	75	Коды на лампах отличаются от тех, которые нанесены на крышки:

	(Рис. 2d, 2e)		квадратные коды крупнее, также есть мелкие прямоугольные коды. Минусы: все коды одинаковые.
D1-Ext	Дополнительные фото крышек (Рис. 2f)	23	Исправлена проблема отсутствия видов сбоку, также добавлены DM-коды другого вида
D1-Aug	Сгенерированные фото (Рис. 2g)	120	<ul style="list-style-type: none"> • Выбраны несколько крышек из исходных и дополнительных данных; • Подобран новый фон (конвейер, металлические листы, темный фон); • Случайно выбраны: количество крышек (1-3), вид этих крышек, фон; • Для каждой случайно выбраны размер, поворот и расположение
D1-Aug2	Аугментированные фото (Рис. 2h)	100	Созданы на основе сгенерированных фото путем изменения яркости, контрастности и насыщенности
D1	Итого:	837	

Примеры изображений из датасета приведены на рис.2.

Для обучения была выбрана SSD архитектура YOLOv8 – последняя версия YOLO. Эта модель работает быстрее и точнее, чем предыдущие версии. Использованные гиперпараметры: `imgsz (1280)`, `epochs (50)`, `batch (8)`, `patience (10)`, размер сети (`nano`, `small`).

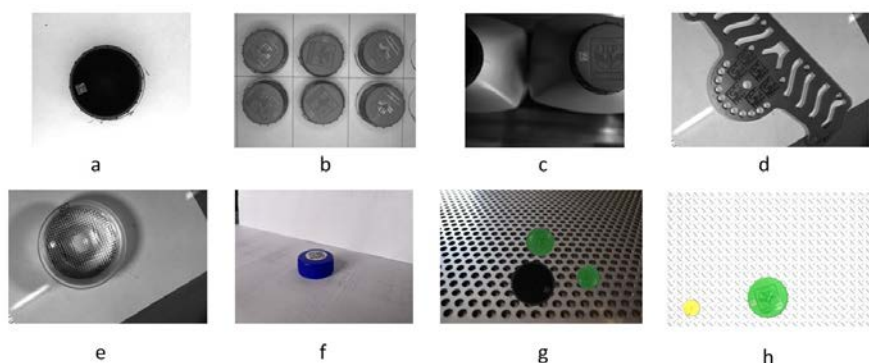


Рис. 2 – Примеры изображений: а – крышки по одной штуке; б – группа крышек;

с – крышки на конвейере; d – элементы лампы (1); е – элементы лампы (2); f – дополнительные крышки; g – сгенерированные; h – аугментированные

4. Экспериментальное исследование

4.1. Выбор размера сети и структуры датасета

Было обучено пять моделей, каждая из которых была проверена на validation set, содержащем изображения из собранного датасета (D1), но не участвовавших в обучении, а также на стороннем датасете [14] (D2).

Различия моделей заключаются в изображениях для обучения и архитектуре. Подробнее данные особенности представлены на Рис. 3.

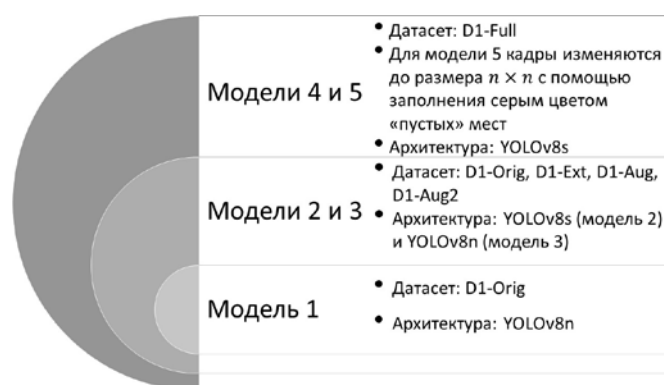


Рис. 3 – Особенности моделей

Для оценки качества работы нейронных сетей применялись стандартные метрики [15]: Precision (точность) и Recall (полнота), Mean Average Precision (mAP, средняя усредненная точность). Для оценки качества перекрытия применялась метрика Intersection over Union (IoU, коэффициент Жаккара) - отношение

площади пересечения двух ограничивающих рамок A и B к площади их объединения. При оценке комбинированного алгоритма использовалась Average Recall (AR, средняя полнота) – среднее значение полноты при IoU, изменяемом от 0.5 до 1.

4.2. Сравнение моделей YOLOv8 на разных типах датасета

Модели сравнивались по показателям mAP по датасету D1 и Recall, Precision по датасету D2. Метрики представлены в табл.2.

Таблица 2

Результаты исследования обученных нейронных сетей

	1	2	3	4	5
mAP D1	0,995	0,991	0,992	0,982	0,975
Recall D2	0,37931	0,310345	0,284483	0,862069	0,775862
Precision D2	0,473118	0,923077	0,868421	0,862069	0,891089

Высокий показатель mAP моделей 1-3 свидетельствует о переобучении, что видно из низких значений метрик при экспериментах на датасете D2 из совершенно новых данных. По итогам экспериментов была выбрана модель 4, обученная на полном датасете D1 исходных размеров, показала лучший результат, что вероятно связано с тем, что модель меньше привязана к форме кода, а больше к паттерну чередующихся темных и светлых пикселей.

4.3. Анализ качества комбинированного алгоритма

Каждый алгоритм был протестирован на test set, содержащем изображения из собранного датасета (D1), но не участвовавших в обучении, а также на стороннем датасете (D2). Результаты экспериментов представлены в табл.3. Основной упор в оценке качества работы алгоритмов делался на среднее время и полноту обнаружения. В таблице отсутствует значение полноты, для всех экспериментов оно было равно 1. Эксперименты проводились на компьютере со следующими характеристиками: процессор i7-4790, оперативная память 32 Гб, видеокарта GeForce GTX 1660 SUPER 6Gb, Ubuntu 22.04.3 LTS, CUDA 11.7.

Таблица 3

Сравнение алгоритмов по результатам экспериментов

Датасет	Алгоритм	Recall	AR	Среднее время (с)
D1	A0-DmtxOnly	0,544	0,616	49,07
	A1-RoiOnly	0,549	0,633	1,40
	A2-FullNetFail	0,549	0,633	2,47
	A3-FullDecFail	0,549	0,633	9,80
	A4-FullMasked	0,554	0,636	50,90
D2	A0-DmtxOnly	0,795	0,866	4,95
	A1-RoiOnly	0,735	0,756	0,41
	A2-FullNetFail	0,778	0,842	0,58
	A3-FullDecFail	0,786	0,860	1,12
	A4-FullMasked	0,863	0,898	5,91

Результаты свидетельствуют о том, что использование нейронной сети позволяет существенно сократить время работы декодера: наиболее быстрым оказалась модель A1, которая передает ридеру только небольшие фрагменты исходного изображения, что ускоряет его работу.

В моделях, использующих нейронную сеть, значение полноты увеличилось в сравнении с моделью по_preп без них для test set и незначительно снизилось (за исключением модели A4) для стороннего датасета. Наивысший показатель полноты у модели A4, она же является самой медленной.

Интересно, что значение полноты одинаково для моделей A1, A2, A3, запущенных на D1. Это объясняется тем, что нейронная сеть находит все читабельные коды, так как была обучена на DM-кодах этого же типа, и при обработке полного изображения ридером новые коды не дешифровываются.

Наилучшее соотношение полноты и скорости оказалось у моделей A2 (скорость выше) и A3 (полнота выше), однако их не рекомендуется использовать на данных, где превалируют кадры без двумерных матричных кодов, так как

время обработки значительно увеличится. Наилучший показатель времени при небольшой потере полноты у модели A1, - его предпочтительно использовать в случаях, когда скорость срабатывания стоит в приоритете. Наилучшее значение полноты у модели A5.

Заключение

Были рассмотрены несколько алгоритмов для обнаружения двумерных матричных кодов, использующие нейронную сеть.

Было проведено сравнение данных моделей с моделью, использующей только декодер без предобработки нейронной сетью. Использование нейронных сетей дает существенный выигрыш во времени, причем на тестовом датасете получилось получить также увеличить полноту.

Направления дальнейших исследований:

- Расширить датасет (добавить изображения DM-кодов другого масштаба, с других ракурсов, на другом фоне)
- Применить семантическую сегментацию (качество расшифровки кода зависит от угла наклона, а при качественной сегментации код можно развернуть для достижения наилучшего положения для последующего декодирования).

Список литературы

1. Ladislav Karrach, Elena Pivarčiová // Comparative Study of Data Matrix Codes Localization and Recognition Methods. 2021.
2. Qiang Huang, Wen-Sheng Chen, Xiao-Yan Huang and Ying-Ying Zhu // Data Matrix Code Location Based on Finder Pattern Detection and Bar Code Border Fitting. Mathematical Problems in Engineering, 2012.
3. Omar Lopez-Rincon, Oleg Starostenko, Vicente Alarcon-Aquino, and Juan C. Galan-Hernandez // Binary Large Object-Based Approach for QR Code Detection in Uncontrolled Environments. Journal of Electrical and Computer Engineering, 2017.
4. Hyeon Cho, Dongyi Kim, Junho Park, Kyungshik Roh, Wonjun Hwang // 2D Barcode Detection using Images for Drone-assisted Inventory Management. 15th International Conference on Ubiquitous Robots (UR), USA, June 27-30, 2018.

5. Dynamsoft Barcode Reader // Сайт Dynamsoft.com (<https://www.dynamsoft.com/barcode-reader/overview/>).
6. What is libdmtx? // Сайт Libdmtx.sourceforge.net (<https://libdmtx.sourceforge.net/>).
7. ML Kit // Сайт Developers.google.com (<https://developers.google.com/ml-kit?hl=ru>).
8. Developer Vision // Сайт Developer.apple.com ([https:// developer.apple.com/documentation/vision](https://developer.apple.com/documentation/vision)).
9. ZXing-C++ // Сайт Github.com (<https://github.com/zxing-cpp/zxing-cpp>).
10. What are the Best Data Matrix Reading SDKs? // Dynamsoft.com (<https://www.dynamsoft.com/codepool/data-matrix-reading-benchmark-and-comparison.html>)
11. Shaoqing Ren, Kaiming He, Ross Girshick, and Jian Sun // Faster R-CNN: towards real-time object detection with region proposal networks. 2015.
12. Wei Liu, Dragomir Anguelov, Dumitru Erhan, Christian Szegedy, Scott Reed, Cheng-Yang Fu, Alexander C. Berg // SSD: single shot multibox detector. 2015.
13. Joseph Redmon, Santosh Divvala, Ross Girshick, Ali Farhadi // You only look once: Unified, real-time object detection. 2015.
14. Tiago Almeida, Vitor Santos, Oscar Martinez Mozos, Bernardo Lourenc // Comparative Analysis of Deep Neural Networks for the Detection and Decoding of Data Matrix Landmarks in Cluttered Indoor Environments. Journal of Intelligent & Robotic Systems, 2021.
15. Rafael Padilla, et. al. // A Comparative Analysis of Object Detection Metrics with a Companion Open-Source Toolkit, 2021.

АППАРАТНАЯ РЕАЛИЗАЦИЯ СЕГМЕНТНОЙ СПАЙКОВОЙ МОДЕЛИ НЕЙРОНА CSNM НА ОПЕРАЦИОННЫХ УСИЛИТЕЛЯХ¹

А.В.Бойко¹, А.В.Бахшиев^{1,2}, А.М. Корсаков³

¹ Санкт-Петербургский политехнический университет Петра Великого,

bakhshiev_av@spbstu.ru

² ООО Системы Компьютерного Зрения

³ Центральный научно-исследовательский и опытно-конструкторский институт робототехники и технической кибернетики

Введение

В современном мире все большее применение находят технологии, основанные на нейронных сетях. Направление спайковых нейронных сетей является важной частью современной нейронауки. Это обусловлено как потребностью в создании энергоэффективных реализацией глубоких нейронных сетей [1], так и поиском новых, более эффективных архитектурных решений. Одним из направлений таких исследований, является попытка реализации вычислений на дендритных деревьях отдельных нейронов, с далеко идущей целью создания архитектур, где функциональным элементом выступает не отдельный нейрон как точечный объект, а сегмент (компармент) дендритного дерева.

Нейробиологические исследования показали, что дендриты нейронов играют важную роль в интеграции синаптических входов, что может увеличить способность нейронов обрабатывать информацию [2, 3]. Применение модели нейрона с учетом описания структуры дендритного дерева предложено в [4], однако модель не рассматривает сигналы в сети как спайковые. Модели, учитывающие структуру нейрона, называют сегментными моделями (compartmental). На данный момент можно выделить двухсегментную модель [5], состоящую из модулей сомы и дендритов и трехсегментную модель, состоящую из модулей сомы, апикальных и базальных дендритов [6]. В работах [7, 8] показывается, что многосегментные модели нейрона, реализованные на нейроморфных чипах, позво-

¹ Работа проводилась в рамках выполнения в ЦНИИ РТК государственного задания Минобрнауки России на 2023 год: “Исследование и разработка биоподобной системы управления поведением мобильных роботов на базе энергоэффективных программно-аппаратных нейроморфных средств” (FNRG-2022-0016 1021060307690-3-1.2.1;2.2.2).

ляют имитировать динамические процессы нейронных цепей мозга при низких энергозатратах. В работе [9] предлагается алгоритм обучения спайковой нейронной сети, использующей многосегментные нейроны для обработки данных о состоянии системы.

В данной работе, предлагается аппаратная реализация модели нейрона CSNM, представленной в работах [10, 11, 12]. Модель CSNM позволяет описывать нейрон как древовидную структуру, состоящую из отдельных сегментов, каждый из которых может содержать произвольное число возбуждающих и тормозных синапсов. Особенностью модели является простота реализации на ней нейронов с различной конфигурацией дендритного и синаптического аппаратов с сохранением возможности описания динамических процессов преобразования импульсных потоков в нейроне. Целью работы было реализовать качественно подобное поведение аппаратной реализации на дискретных элементах с возможностью, в будущем формирования требуемой структуры мембраны вручную.

В разделе 1 представлена краткий обзор подходов к реализации спайковых моделей нейронов на аналоговой электронике, в разделе 2 описано предлагаемое решение, в разделе 3 демонстрируются результаты симуляции.

1. Обзор подходов к аппаратной реализации моделей нейронов на аналоговой элементной базе

Большинство схем используют транзисторные каскады для реализации уравнений модели [13, 14]. Транзисторы не потребляют много энергии, работают при низких напряжениях, имеют малые габариты и довольны высокий КПД, но при этом чувствительны к температуре и статическому электричеству. Эти недостатки устраняют с помощью обратных связей в результате чего схемы становятся довольно сложными для восприятия и расчета. Кроме того, схемы на транзисторах чувствительны к параметрам элементов в нем, особенно к качеству транзисторов. Если схема симметрична, то практически обязательным требованием является использование транзисторов из одной партии. При сборке схем на дискретной элементной базе это необходимо учитывать.

В некоторых реализациях кроме транзисторных каскадов используются и

операционные усилители (ОУ), чаще в схемах для обучения нейросетей. ОУ обычно выполняет вспомогательную функцию, например по объединению нейронов определенным образом или созданию положительной обратной связи. Иногда ОУ используется в качестве компаратора с гистерезисом. В некоторых реализациях ОУ играет главную роль, например в [15] ОУ используется в качестве интегратора в синапсе. В работе [14] предложен синапс с использованием ОУ для сохранения бистабильности.

Операционные усилители не пользуются большой популярностью при реализации спайковых нейронных сетей, так как математические модели обычно описывают поведение тока внутри нейрона, а операционные усилители преобразуют именно напряжение. Исключением является синапс, который как в модели, так и в реализациях, оперирует входным напряжением, но выходом все равно является синаптический ток.

Схемы на операционных усилителях отличаются постоянством и надежностью характеристик. Параметры такой схемы практически полностью зависят от внешних элементов, а не самого ОУ, поэтому тщательный подбор элементов здесь не нужен. Существуют готовые схемы на ОУ для типовых операций и звеньев теории автоматического управления, которые практически не требуют дополнительной настройки. Также при каскадном подключении схемы на ОУ обладают меньшим шумом по сравнению с каскадным подключением транзисторных схем. И, в случае с сегментной реализацией, очень важна повторяемость параметров одинаковых сегментов, что трудно ожидать от транзисторных схем на дискретных элементах.


Относительно недавно в реализациях появился новый подход – использование мемристоров. Мемристор это элемент, который сохраняет определенное значение своего сопротивления в зависимости от проходившего через него тока. В реализациях он обычно используется для хранения веса нейрона, что облегчает обучение нейросети.

В одной из аналоговых реализаций [16] мемристор используется как генератор.

Мемристоры пока являются довольно новыми компонентами и еще не настолько хорошо изучены, и описаны. Они имеют несколько недостатков: от одного цикла переключения к другому они слегка меняют свои характеристики, и так же, как транзисторы, обладают вариацией характеристик от одного устройства к другому.

2. Аппаратная реализация модели CSNM на операционных усилителях

Рассматриваемая модель нацелена на реализацию пластичности нейрона через изменение структуры мембраны и числа синапсов, поэтому для сохранения всех функций модели нет необходимости обеспечивать изменение веса синапса. Также, поскольку планировалось использование дискретных элементов, в основу были положены операционные усилители. Вопросы оптимизации энергопотребления и сложности схемотехнических решений в рамках данной работы не рассматривались.



X, Y – входной и выходной сигналы соответственно (прямоугольный импульс)

U_1, U_2 – потенциал на входе и выходе модели сегмента мембраны

W – вклад синапса в изменение потенциала мембраны

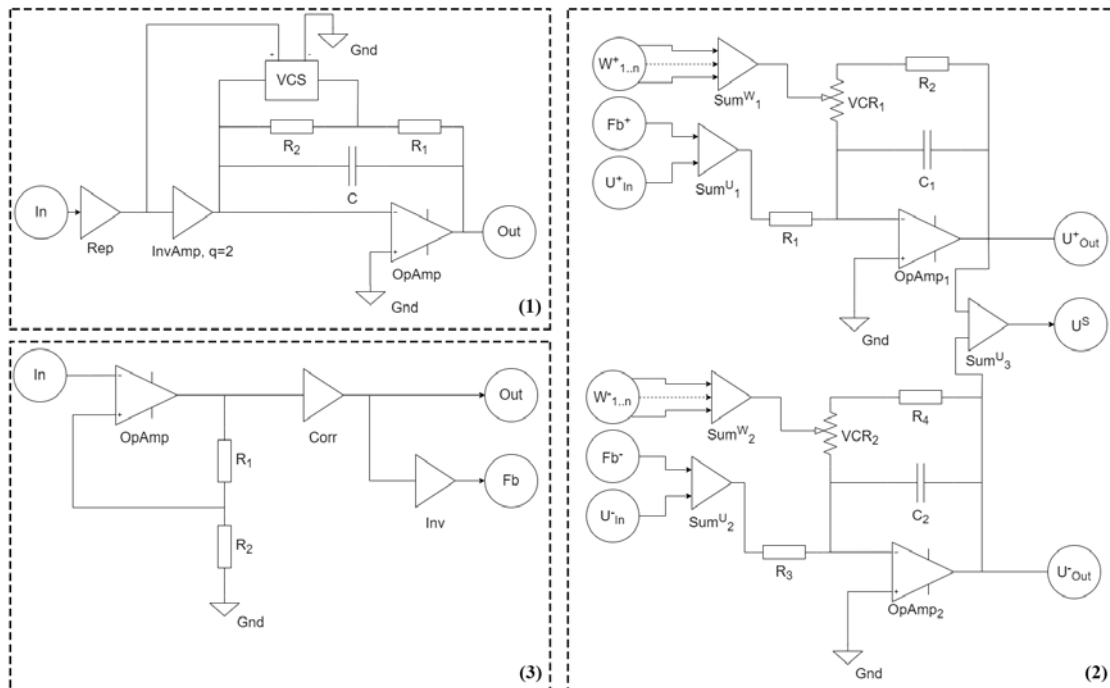
H – влияние генератора на изменение потенциала мембраны (обратная связь)

Рис.1. Структурная схема аппаратной реализации нейрона

Аппаратная реализация делится на следующие модули аналогично модели CSNM: синапс, сегмент мембраны и генератор импульсов. Далее эти структурные элементы можно комбинировать, формируя нейрон с различной организацией дендритного и синаптического аппарата. Для примера, на рис.1 изображена схема простейшего нейрона с одним синапсом и мембраной.

На рис.2 приведены схемы функциональных элементов модели. Использо-

вание напряжения как носителя сигнала вытекает из факта использования ОУ.



(1) – Синапс

(2) – сегмент мембраны

(3) – генератор импульсов

Рис.2. Схемы функциональных элементов модели

Здесь: In – вход, Out – выход, Rep – повторитель, InvAmp – инвертирующий усилитель, q – коэффициент усиления, VCS – управляемый напряжением ключ, R – сопротивление, C – емкость, OpAmp – операционный усилитель, Gnd – земля, $W_{1..n}$ – сигнал с синапса, Fb – обратная связь, U_{in} – входное напряжение, Sum^w – сумматор сигналов с синапса, Sum^u – сумматор напряжений, VCR – управляемое напряжением сопротивление, U_{out} – выходное напряжение, U_s – суммарное напряжение, Corr – корректировщик, Inv – инвертор.

В модели CSNM синапс представлен апериодическим звеном 1-го порядка с логическим управлением постоянной времени. На вход синапса подается положительный прямоугольный импульс длительностью 1 мс, и амплитудой 5В. Так как на выходе мы хотим получить положительный отклик синапса, а ОУ инвертирует сигнал, мы предварительно инвертируем импульс с помощью инвер-

тирующего усилителя с коэффициентом усиления 1.

Синапс должен обладать разными постоянными времени во время своего роста (когда импульс активен) и своего спада (когда импульса отсутствует). Постоянная времени апериодического звена на ОУ зависит от сопротивления R_1 и емкости C обратной связи ($T = R_1C$), поэтому, чтобы менять постоянную времени, нужно менять сопротивление или емкость. Добавление емкости вызывает «просадки» сигнала при зарядке конденсатора, поэтому было принято решение управлять сопротивлением. Для этого в участок обратной связи был добавлен ключ, управляемый напряжением (VCS), с параллельным ему добавочным сопротивлением R_2 . На затвор подается импульс с генератора, таким образом когда импульс есть – VCS замыкается и шунтирует сопротивление R_2 ($T_{воз} = R_1C$), когда импульс отсутствует – VCS размыкается и сопротивление R_2 участвует в цепи ($T_{снод} = [R_1 + R_2]C$). Сопротивления были подобраны так, чтобы временные постоянные были приближены к таковым в модели.

Так как напряжение импульса делится на две ветви и уменьшается, коэффициент инвертирующего усилителя был изменен на 2.

Также выход с генератора импульсов, является выходом с операционного усилителя (т.е. низкоомный выход), а при подключении следующего нейрона должен идти на вход другого ОУ в синапсе (т.е. высокоомная нагрузка), и для избежания помех сигнала в синапсе применен повторитель входного сигнала.

Функциональная схема сегмента мембраны представлена на рис.2(2). Реализация сегмента состоит из двух частей (ионных механизмов), обеспечивающих условно положительный и отрицательный вклады в потенциал. Разделение на полярность считается условным, потому что играет роль только знак при сложении значений, само напряжение в каждой части положительное. Каждый ионный механизм, по сути, представляет собой апериодическое звено первого порядка с обратной связью. Сигнал синапса участвует в обратной связи и в постоянной времени апериодического звена. Если пересчитать этот элемент с учетом обратной связи, то так же, как для синапса, можно получить интегратор со следующим

выражением для выходной характеристики:

$$U_{out} = \frac{C_m p + g^2 R_m + g}{(g + 1/R_m) p} U_{in},$$

где C_m - емкость мембраны,

R_m - сопротивление мембраны,

g - суммарная текущая проводимость синапсов.

Предложенная реализация не обеспечивает точного соответствия, но решение было подобрано так, чтобы качественно повторять поведение математической модели.

Для реализации изменяемой временной характеристики было использовано сопротивление, управляемое напряжением (управляемое сопротивление). На данный момент в схеме оно представлено виртуальным элементом.

Входными сигналами для сегмента мембраны являются два входа для потенциалов (в случае конечного сегмента дендрита в цепочке это потенциал с источника напряжения, а в случае последующих, это вклады с предыдущих сегментов); два входа для сигналов с синапсов (тормозящий и возбуждающий) и два входа для обратной связи (ОС) на каждый из потенциалов. Выходными сигналами являются два выхода для потенциала каждого знака и выход для суммы потенциалов. Разделение на полярность считается условным, потому что играет роль только знак при сложении значений, само напряжение в каждой части положительное.

На входе для сигналов с синапса стоят инвертирующие сумматоры, которые позволяют подключать на вход мембраны несколько синапсов с разными весами.

Принцип работы генератора выходных импульсов таков: сигнал обратной связи и выходной импульс начинают генерироваться, когда сигнал на входе выше определенного уровня (P_1), а заканчивается генерироваться, когда ниже другого уровня (P_2 , $P_2 < P_1$). Такому поведению полностью соответствует компаратор с гистерезисом на операционном усилителе (ОУ). Функциональная схема генератора импульсов представлена на рис.2(3).

Параметры компаратора (значения порогов) задаются через отношения сопротивлений R_1 и R_2 и максимального и минимального напряжений на ОУ. Компаратор выдает свой отрицательный нижний порог, поэтому он «сдвигается» до нуля суммированием результата компаратора с дополнительным напряжением, противоположным нижнему порогу. Этот элемент схемы представлен как «Согг» Далее сигнал с соответствующим знаком идет на выход и на обратную связь (ОС).

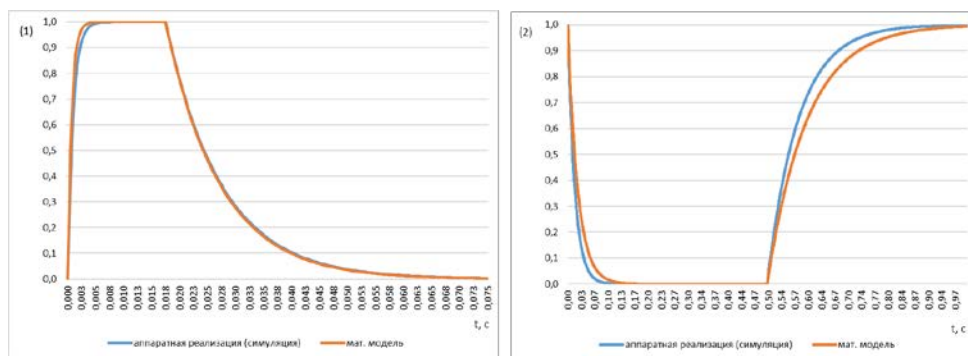
3. Экспериментальное исследование

Для того, чтобы сравнить полученную аппаратную реализацию был поставлен следующий эксперимент. В качестве входа на синапс и ионных механизм сегмента мембраны подавались одинаковые сигналы: импульс (прямоугольный сигнал длительностью 1 мс) и ступенька (прямоугольный сигнал длительностью в 1 с). Временем возрастания считалось время, когда сигнал изменяется от 5% до 95% расстояния между экстремумами, время спада соответственно наоборот. Результаты экспериментов представлены в таблице.

Таблица. Время возрастания и спада выходного сигнала реализации синапса и ионного механизма сегмента мембраны, мс

	Синапс						Сегмент мембраны					
	Модель		Аппаратная симуляция		Δ		Модель		Аппаратная симуляция		Δ	
	$T_{\text{воз}}$	$T_{\text{спад}}$	$T_{\text{воз}}$	$T_{\text{спад}}$	$T_{\text{воз}}$	$T_{\text{спад}}$	$T_{\text{воз}}$	$T_{\text{спад}}$	$T_{\text{воз}}$	$T_{\text{спад}}$	$T_{\text{воз}}$	$T_{\text{спад}}$
Импульс	1	29	0,8	29,2	0,2	0,2	102	1,5	97	1,5	7	0
Ступенька	2	28,5	2,9	29,2	0,9	0,7	294	78	228,7	55,3	63,3	22,7

Для наглядности результаты были нормированы и представлены на рис. 3 (продолжительные плато урезаны для компактности), по оси абсцисс указано время (сек).



(1) – Реакции синапса

(2) – Реакции ионного механизма сегмента мембраны

Рис.3. Реакции синапса и ионного механизма сегмента мембраны на ступенчатое входное воздействие

Можно видеть, что качественно аппаратная реализация повторяет поведение математической модели. Рассогласование обусловлено спецификой аппаратной реализации, а также некоторыми допущениями в реализации сегмента мембраны. Тем не менее результаты качественно соответствуют друг другу. Полученная количественная погрешность в длительности переходных процессов может быть компенсирована эмпирической коррекцией параметров модели.

Заключение

Был проведен анализ существующих подходов к аппаратной реализации спайковых нейронов на дискретных аналоговых элементах. Разработаны схемы реализаций функциональных элементов модели CNSM, проведена эмпирическая настройка полученной схемы под типовые параметры математической модели.

Преимуществом предложенного решения является его модульность, то есть возможность собирать произвольные конфигурации структуры мембраны нейрона.

Для оценки качества полученного решения проведены эксперименты со сравнением отклика синапса и сегмента мембраны на типовые входные воздействия. Эксперименты показали, что реализация повторяет временные характеристики, которые наблюдаются в математической модели, что позволит использовать ее для аппаратной реализации предобученных спайковых нейронных сетей.

Из недостатков на данном этапе можно выделить сложность описания

схемы, недостаточно эффективное энергопотребление, неопределенность в физической реализации некоторых элементов схемы, необходимость эмпирической подстройки временных параметров схемы.

В качестве перспективных направлений работ можно выделить следующие: необходимость разработки метода сравнения амплитуд в математической модели с амплитудами в её аппаратной реализации; проведение дополнительных экспериментов с отдельными нейронами и цепочками нейронов; оптимизацию схемы и сборку прототипов.

Список литературы

1. Bouvier, M., Valentian, A., Mesquida, T., Rummens, F., Reyboz, M., Vianello, E., & Beigne, E. (2019). Spiking neural networks hardware implementations and challenges: A survey. *ACM Journal on Emerging Technologies in Computing Systems (JETC)*, 15(2), 1-35.
2. Smith S. L. et al. Dendritic spikes enhance stimulus selectivity in cortical neurons in vivo //*Nature*. – 2013. – Т. 503. – №. 7474. – С. 115-120.
3. Gidon A. et al. Dendritic action potentials and computation in human layer 2/3 cortical neurons //*Science*. – 2020. – Т. 367. – №. 6473. – С. 83-87.
4. Khan G.M., Miller J.F. In search of intelligence: evolving a developmental neuron capable of learning//*Connection Science*. – 2014. – Vol. 26. – In search of intelligence. – No. 4. – P. 297-333.
5. Urbanczik R., Senn W. Learning by the dendritic prediction of somatic spiking //*Neuron*. – 2014. – Т. 81. – №. 3. – С. 521-528.
6. Sacramento J. et al. Dendritic cortical microcircuits approximate the backpropagation algorithm //*Advances in neural information processing systems*. – 2018. – Т. 31.
7. Shrestha A. et al. In-hardware learning of multilayer spiking neural networks on a neuromorphic processor //*2021 58th ACM/IEEE Design Automation Conference (DAC)*. – IEEE, 2021. – С. 367-372.
8. Kopsick J. D. et al. Robust resting-state dynamics in a large-scale spiking neural network model of area ca3 in the mouse hippocampus //*Cognitive Computation*. – 2022. – С. 1-21.

9. Sun Y. et al. Multi-compartment Neuron and Population Encoding improved Spiking Neural Network for Deep Distributional Reinforcement Learning //arXiv preprint arXiv:2301.07275. – 2023.
10. А.В. Бахшиев, С.П. Романов. – Математическое моделирование процессов преобразования импульсных потоков в естественном нейроне // Нейрокомпьютеры: разработка, применение, №3, 2009. – с.71-80.
11. Aleksandr Bakhshiev, Filipp Gundelakh. Mathematical Model of the Impulses Transformation Processes in Natural Neurons for Biologically Inspired Control Systems Development // Supplementary Proceedings of the 4th International Conference on Analysis of Images, Social Networks and Texts (AIST-SUP 2015), Yekaterinburg, Russia, April 9-11, 2015. Published on CEUR-WS, vol. 1452, pp. 1-12, 15.10.2015. Online: <http://ceur-ws.org/Vol-1452/>
12. Бахшиев, А. В. Сегментная спайковая модель нейрона CSNM / А. В. Бахшиев, А. А. Демчева // Известия высших учебных заведений. Прикладная нелинейная динамика. – 2022. – Т. 30. – № 3. – С. 299-310. – DOI 10.18500/0869-6632-2022-30-3-299-310.
13. E. Chicca, F. Stefanini, C. Bartolozzi and G. Indiveri, "Neuromorphic Electronic Circuits for Building Autonomous Cognitive Systems," Proceedings of the IEEE, vol. 102, no. 9, pp. 1367 - 1388, 2014.
14. M. R. Azghadi, N. Iannella, S. F. Al-Sarawi, G. Indiveri and D. Abbott, "Spike-Based Synaptic Plasticity in Silicon: Design, Implementation, Application, and Challenges," Proceedings of the IEEE, vol. 102, no. 5, pp. 717-737, 2014.
15. S. Millner, A. Grubl, K. Meier, J. Schemmel and M.-O. Schwartz, "A VLSI Implementation of the Adaptive Exponential," Advances in Neural Information Processing Systems, vol. 23, p. 1642–1650, 2010.
16. F. T. Zohora, S. Debnath and A. H.-u. Rashid, "Memristor-CMOS Hybrid Implementation of Leaky Integrate and Fire Neuron Model," in International Conference on Electrical, Computer and Communication Engineering (ECCE), Cox'sBazar, Bangladesh, 2019.

НЕЙРО-НЕЧЕТКАЯ СЕТЬ ДЛЯ ОПРЕДЕЛЕНИЯ СТЕПЕНИ ТЯЖЕСТИ ВНЕБОЛЬНИЧНОЙ ПНЕВМОНИИ²

А.В. Бутусов¹, Хайдер Али Хуссейн Алавси¹, С.А. Филист¹, В.В. Песок¹,
А.Е. Пшеничный¹

¹Юго-Западный государственный университет,
кафедра биомедицинской инженерии, *SFilst@gmail.com*

Внебольничная пневмония (ВП) занимает лидирующую позицию в структуре смертности от инфекций нижних дыхательных путей и ассоциирована с высокой заболеваемостью и неблагоприятным прогнозом. ВП в 88,9 % случаев заканчивается выздоровлением больных. Результаты проведенных исследований показывают, что промедление с госпитализацией пациента резко ухудшает прогноз заболевания [1]. В связи с этим на первое место выходит своевременная оценка степени тяжести ВП с последующим принятием решения по лечению пациента в стационаре или амбулаторно.

При мониторинге состояния больного пневмонией в амбулаторных условиях главной задачей является оценка степени тяжести пневмонии, на основании которой ведется прогноз заболевания и принимается решение о возможном переходе на лечение в условиях стационара. Цель исследования – создание решающего модуля для прогнозирования степени тяжести ВП, позволяющего обеспечить интеллектуальную поддержку при принятии решений медицинским персоналом по госпитализации пациента по факторам риска (ФР), используемых в рутинной практике врача-пульмонолога и получаемых в посредством телемониторинга [2, 3].

В настоящий момент существует целый ряд диагностических приёмов, позволяющих разделить все ВП на две категории — тяжёлые и нетяжёлые. Чаще всего для принятия такого решения используют две шкалы риска: шкала CURB-65 и шкала CRB-65. Однако это балльные интервальные шкалы, решения по которым носит консультативный характер, и которые требуют для повышения надежности их прогноза размытие точечной балльной оценки по интервальной шкале. Поэтому за основу такой шкалы

² Работа выполнена в рамках реализации программы развития ФГБОУ ВО «Юго-Западный государственный университет» программы стратегического академического лидерства «Приоритет-2030»

возьмем структуру многоагентного иерархического классификатора, которая описана в [4, 5]. Основная идея построения этого классификатора заключается в сегментировании ФР на относительно независимые подмножества (СФР) с привязкой каждого такого подмножества к автономному интеллектуальному агенту (АИА). Пространство ФР для оценки степени тяжести пневмонии разделим на СФР, например, данные физикального обследования (СФР1), лабораторные данные (СФР2), рентгенологические данные (СФР3), и т.д. В каждом СФР для классификации данных используем соответствующий АИА. Для агрегирования решений АИА используется мета-классификатор, который выносит окончательное решение по уровню степени тяжести ВП.

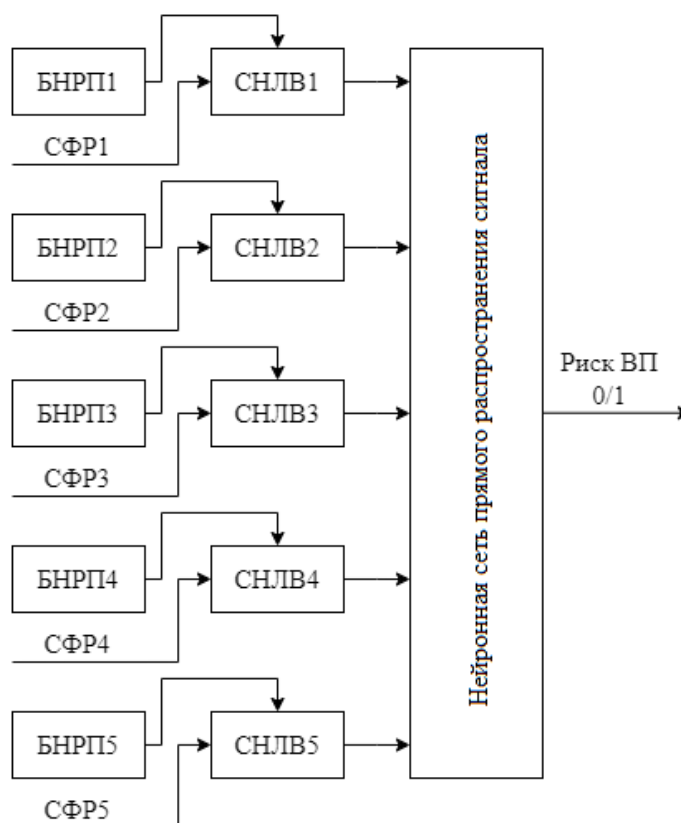


Рис. 1 – Структура нейро-нечеткой сети для классификации степени тяжести внебольничной пневмонии

Для построения многоагентной системы классификации используют формальные методы, среди которых одними из наиболее популярных являются нейронные сети (НС). НС – это обучаемые классификаторы, способные обобщать данные, но не дающие представление о сущности процесса классификации и процесса обучения, что вызывает ряд проблем, связанных с оптимальным объемом обучающей выборки и исключения локальных экстремумов при обучении.

Поэтому специалисты обращают внимание на системы нечеткого логического вывода (СНЛВ), которые позволяют объяснить получаемый с их помощью результат, и тем самым подключают априорный опыт врачей-экспертов к процессу классификации. Однако они не имеют возможности обучаться и обобщать накопленные знания. От перечисленных недостатков пытаются избавиться на основе нейро-нечетких сетей (NFN), которые имеют возможность использовать лингвистические данные, приобретать новые знания, обучаться, выполнять классификацию данных и объяснить полученный результат [6]. На рисунке 1 представлен пример структуры NFN с пятью сегментами ФР.

Проиллюстрируем создание одной из СНЛВ для NFN на примере шкалы риска ВП CRB–65, которая оценивает риск ВП по четырех балльной шкале и предлагает анализ четырех признаков:

x_1 - нарушение сознания, обусловленное пневмонией;

x_2 - тахипноэ ≥ 30 в минуту;

x_3 - снижение систолического артериального давления (АД) < 90 мм рт. ст. или диастолического АД ≤ 60 мм рт. ст.;

x_4 - возраст пациента ≥ 65 лет.

Наличие каждого признака оценивается в 1 балл:

– 0 баллов – амбулаторное лечение;

– 1–2 балла – наблюдение и оценка в стационаре;

– 3–4 баллов – неотложная госпитализация [7].

Структура модуля СНЛВ, входящего в NFN, представлена на рисунке 2. За ее основу взята пятислойная модель нечеткого логического вывода Мамдани-Ларсена. Нулевой слой содержит пять входных переменных.

При этом входная переменная «артериальное давление» (x_3) структурирована на две переменные, но, учитывая, что их влияние на риск ВП эквивалентно, они объединяются в фаззификаторе второго слоя по нечеткому ИЛИ.

В фаззификаторе первого слоя каждой входной переменной -ФР соответствует только одна одноместная функция принадлежности (ФП), за исключением x_3 , по причине, указанной выше.

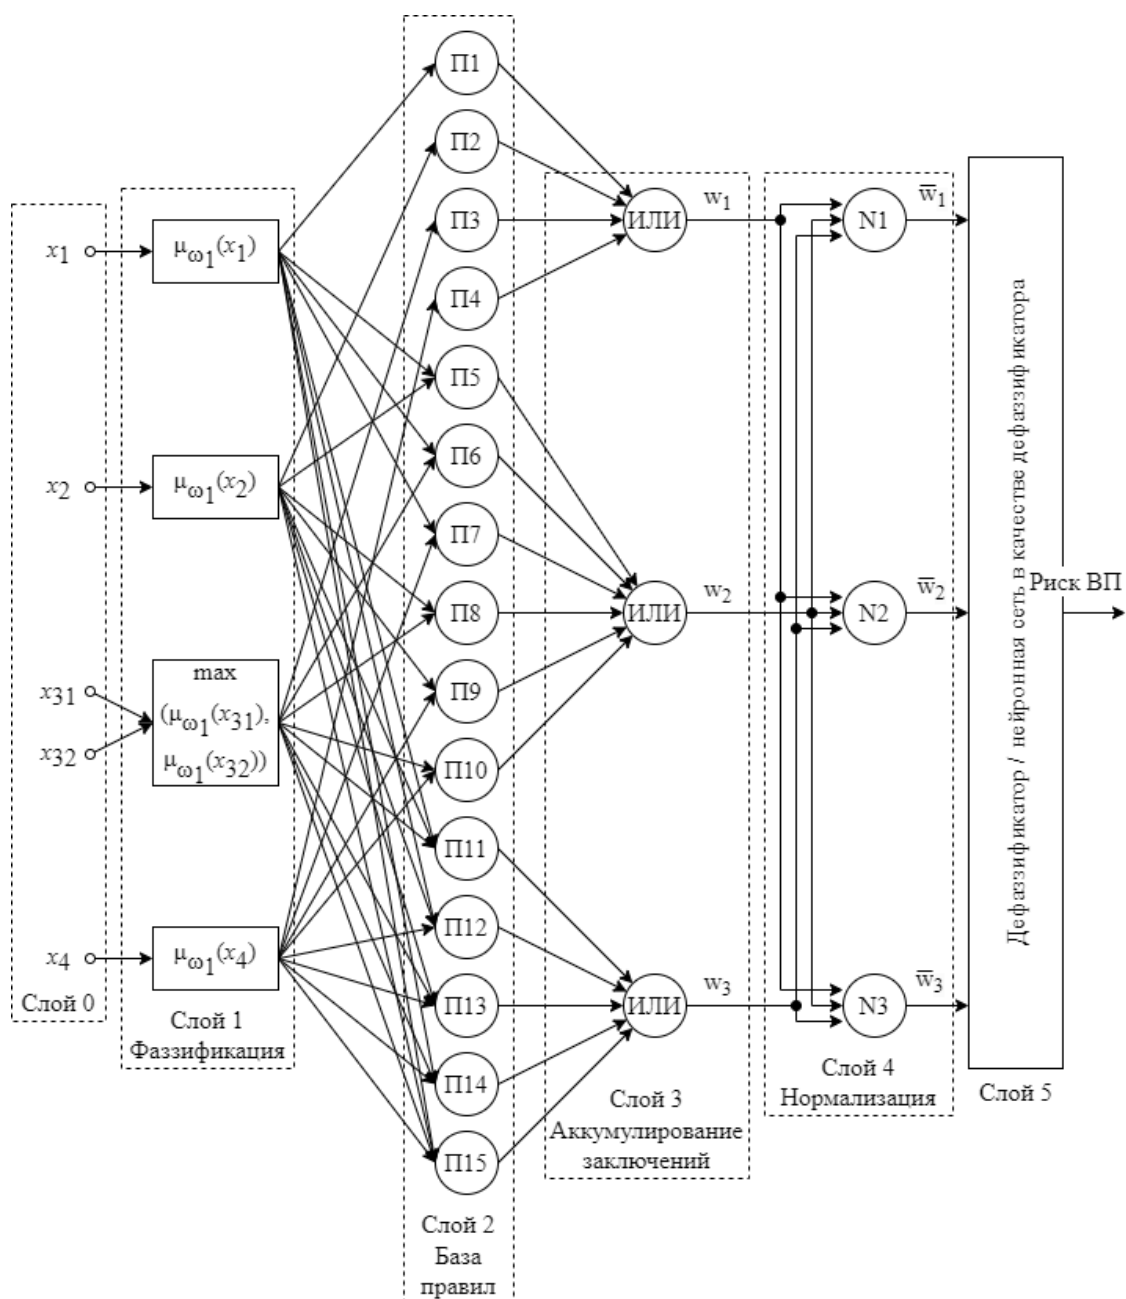


Рис.2. Структурная схема модуля СНЛВ для нейро-нечеткой сети для классификации риска внебольничной пневмонии.

Второй слой NFN является слой базы правил нечетких решающих правил (НРП), которые представлены следующими нечеткими продукциями:

$$\text{ЕСЛИ } x_i \text{ ТО } y = \text{«низкий»}. \quad (1)$$

Следующие шесть НРП запишутся так:

$$\text{ЕСЛИ } (x_i \text{ И } x_j) \text{ ТО } y = \text{«средний»}, \quad (2)$$

где $i \neq j$.

Следующие четыре НРП запишутся так:

$$\text{ЕСЛИ } (x_i \text{ И } x_j \text{ И } x_q) \text{ ТО } y = \text{«высокий»}, \quad (3)$$

где $i \neq j \neq q$.

И, наконец, последнее НРП:

$$\text{ЕСЛИ } (x_1 \text{ И } x_2 \text{ И } x_3 \text{ И } x_4) \text{ ТО } y = \text{«высокий»}. \quad (4)$$

После вычисления их антецедентов вычисляются их консеквенты, которые аккумулируются в третьем слое согласно термам риска ВП. Каждый узел в слое 3 вычисляет максимальное значение в аккумулируемой группе НРП. Учитывая, что подзключения решающих правил умножаются на элементы множества C , которые больше или равны единицы, выходы w_i слоя 3 могут превосходить значения единицы, поэтому для нормализации степени истинности они преобразуются в слое 4 согласно формуле

$$\bar{w}_i = \frac{w_i}{\sum_{i=1}^4 w_i}. \quad (5)$$

Выходная переменная NFN является лингвистической переменной, которая имеет следующие термы: «низкий риск - ω_1 », «средний риск - ω_2 », «высокий риск - ω_3 ». На рисунке 3 представлены ФП, соответствующие этим термам.




Рис. 3 - Графики функций принадлежности термов выходной переменной $y =$ «Риск ВП»

Дефазификации осуществляется по методу центра тяжести или путем использования в качестве дефазификатора обучаемой НС прямого распространения сигнала [8, 9].

Для экспериментального исследования показателей качества классификации риска ВП разработанного ММК, на основе ретроспективного анализа историй болезни пациентов лечебных учреждений г. Курска с диагнозом «внебольничная пневмония» была сформирована экспериментальная группа в количестве 200 пациентов больных ВП различной степени тяжести. В нее было включено 72 тяжелых больных и 128 больных с легкой и средней тяжестью пневмонии.

Используя получаемые различные показатели, характеризующие риск тяжести ВП, как шкалы для построения гистограмм распределения классов ω_1 , ω_2 и ω_3 , были определены классификационные пороги, позволившие решать задачу ROC-анализа. Полученная модель NFN была проанализирована посредством ROC-анализа. ROC-кривая представлена на рисунке 4. Площадь под кривой (AUC) составила 0,88 (очень хорошее качество модели, $p < 0,001$).




Рис. 4 – ROC – кривая полученной модели нейро-нечеткого классификатора степени тяжести внебольничной пневмонии

Осуществлено сопоставление результатов полученной модели риска ВП с результатами экспертного оценивания и результатами, полученными на известных регрессионных моделях. Модель классификатора на контрольной выборке продемонстрировала очень хорошую прогностическую способность ($AUC=0,88$), при чувствительности ДС = 90%; специфичности ДС=86%. В качестве прототипа для NFN была выбрана регрессионная модель [10]. Модель включает два уравнения многомерной линейной регрессии, которые соответствуют двум классам степени тяжести ВП.

Показатели качества классификации синтезированного нейро-нечеткого классификатора позволяют рекомендовать его для телекоммуникационных систем дистанционного мониторинга степени тяжести внебольничной пневмонии.

Список литературы

1. Restrepo MI, Mortensen EM, Rello J., et al. Late admission to the ICU in patients with community-acquired pneumonia is associated with higher mortality. *Chest* 2010; 137:552-7.
2. Бутусов, А.В. Алгоритмы мониторинга эффективности терапевтических и реабилитационных процедур по показателям клинического анализа крови в системе поддержки принятия врачебных решений/ А.В. Бутусов, А.В. Киселев, Е.В. Петрунина, Р.И. Сафронов, В.В. Песок, А.Е. Пшеничный // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. – 2023. – Том 13, № 1. – С. 170-190.
3. Петрова, Т.В. Распределенные автономные интеллектуальные агенты для мониторинга и мета-анализа эффективности управления живыми системами / Т.В. Петрова, Кузьмин А.А., Савинов Д.Ю., Серебровский В.В. // Прикаспийский журнал: управление и высокие технологии. – 2017. – № 4 (40). – С. 61-73.
4. Курочкин, А.Г. Использование гибридных нейросетевых моделей для многоагентных систем классификации в гетерогенном пространстве информативных признаков / А.Г. Курочкин, В.В. Жилин, С.А. Филист, С.А. Суржикова // Прикаспийский журнал: управление и высокие технологии. – Астрахань: ФГБОУ

- ВО «Астраханский государственный университет», 2015. – №3 (31). – С. 85-95.
5. Курочкин, А.Г. Нейросетевые модели для мета-анализа медико-экологических данных / А.Г. Курочкин, В.В. Протасова, С.А. Филист, А.Н. Шуткин // Нейрокомпьютеры. Разработка, применение. – М.: Радиотехника, 2015. – №6. – С. 42-48.
 6. Ермаков, С.А. Оценка риска с использованием нейро-нечеткой системы / С.А. Ермаков, А.А. Болгов // Информация и безопасность. – 2022. – Т. 25. Вып. 4. – С. 583-592. – DOI: 10.36622/VSTU.2022.25.4.012.
 7. Фисенко, О.В. Тяжелая внебольничная пневмония и шкалы оценки прогноза / О.В. Фисенко, А.И. Синопальников // Практическая пульмонология. – 2014. – № 2. – С.20-26.
 8. Жилин, В.В. Способ моделирования нечетких моделей в пакете MATLAB для биомедицинских приложений / В.В. Жилин, С.А. Филист, Р.С. Халед Абдул, О.В. Шаталова // Медицинская техника. Москва. – 2008. – №2. – С. 15-18.
 9. Жилин, В.В. Гибридный способ классификации биосигналов на основе технологий нечеткой логики принятия решений и нейронных сетей / В.В. Жилин, С.А. Филист, В.А. Аль-Муаалеми // Биомедицинская радиоэлектроника. – 2009. – №5. – С. 77-82.
 10. Сиротко, И.И. Математические модели внебольничной пневмонии / И.И. Сиротко, Р.Г. Самойлов // Сибирский медицинский журнал – 2007. – №2. – С.5-10.

ОПРЕДЕЛЕНИЕ ПОКАЗАТЕЛЕЙ ДМПП С ПОМОЩЬЮ МАШИННОГО ОБУЧЕНИЯ

И.А. Демичев¹, В.В. Сакович¹, М.Г. Садовский^{1,2,3}, С.Д. Гусев¹

¹ФГБОУ ВО КрасГМУ им. проф. В.Ф. Войно-Ясенецкого Минздрава России

²Сибирский федеральный университет

³Институт вычислительного моделирования СО РАН

msad@icm.krasn.ru

Дефект межпредсердной перегородки (ДМПП) – это врожденный порок сердца (ВПС), характеризующийся наличием сообщения (отверстия) между правым и левым предсердием (рисунок 1), который обуславливает существование артериовенозного сброса между ними. Частота встречаемости ДМПП составляет 7,1-8,7% от всех врожденных пороков сердца [1]. Заболеваемость ДМПП колеблется от 0,317 до 0,941 случая на 1000 живорожденных детей в зависимости от популяции, методов диагностики и времени эпидемиологических исследований [1]. ДМПП в большинстве популяций чаще встречается у женщин, чем у мужчин [2,3].

Гемодинамические изменения, которые характерны для ДМПП, представлены аномальным сбросом артериальной крови из левого предсердия в правое предсердие, что является причиной смешивания крови и появления постоянно циркулирующего объема крови в малом круге кровообращения (МКК). Это ведет к перегрузке правых отделов сердца и развитию легочной гипертензии (ЛГ) [4]. Гемодинамические перегрузки, возникающие вследствие патологических гемодинамических изменений, могут приводить к гипертрофии МЖП. [5]

Наиболее действенным и современным инструментом в постановке диагноза ДМПП является трансторакальная эхокардиография (ЭхоКГ) с применением режима цветного доплеровского картирования [1,5].

Полная ЭхоКГ включает описание анатомических характеристик дефекта, направления сброса крови, сопутствующих дефектов сердца (аномальный дренаж легочных вен), анатомических и функциональных характеристик правого желудочка, давления в легочной артерии и соотношения системного и легочного

кровотоков.




Рис. 1. Дефект межпредсердной перегородки.

При этом вопрос об определении времени плановой коррекции дефекта – все ещё остается открытым.

Целью нашего исследования является анализ эффективности эхокардиографических параметров и выделение информационно-значимых параметров для задач диагностики ДМПП с помощью методов машинного обучения (сверточных нейронных сетей).

Результаты: Определён показатель, вносящий наибольшую роль в решение задачи классификации с помощью метода машинного обучения.

Структурные показатели включали в себя линейные размеры и объемы полостей сердца, массу миокарда ЛЖ (ММ ЛЖ), толщину межжелудочковой перегородки и задней стенки ЛЖ (ЗСЛЖ).

В качестве функциональных показателей были использованы фракция выброса и фракция укорочения ЛЖ (ФВ ЛЖ и ФУ ЛЖ), время выброса крови в аорту, амплитуда и скорость движения латеральных сегментов митрального (MAPSE, LVs) и трикуспидального (TAPSE, RVs) клапанов, пиковые скорости и продолжительность фаз пассивного (E) и активного (E') наполнения желудочков.

Антропометрические показатели включали в себя массу (кг), рост (см), пол (М, Ж), возраст (полных лет).

В построении модели машинного обучения используется Sequential модель, которая представляет собой линейную совокупность слоев, пакета Keras –

официального бэкэнда TensorFlow.

Оценка качества классификации проводилась с помощью показателей точности (accuracy), чувствительности (sensitivity), специфичности (specificity) и площади под ROC-кривой (AUC),

Таблица 1. Таблица результирующих показателей

Показатель	Значение
Точность (accuracy)	0,88
Чувствительность (sensitivity)	0,75
Специфичность (specificity)	0,95
Площадь под ROC-кривой (AUC)	0,84

Определение эхокардиографических показателей, вносящих наибольшую роль в решение задачи классификации, производилось с помощью последовательного перебора исключаемых показателей и фиксацией точности обучаемой модели с удаленным показателем.




Рис. 2. Диаграмма зависимости точности модели на проверочных данных в зависимости от исключённого показателя

Таким образом, показателем, вносящим наибольшую роль в решении задачи классификации (наличие ДМПП / отсутствие ДМПП), оказался показатель

«ПП площадь» - площадь правого предсердия.

Лидирующую роль данного показателя можно объяснить патологическим увеличением правого предсердия вследствие значимого выброса крови из овального отверстия в правое предсердие при данном ВПС.

Полученные показатели оценки классификации наряду с выделенными диагностическими признаками указывают на возможность создания модели высокой точности предсказания наличия дефекта межпредсердной перегородки.

Модели врожденных пороков сердца могут использоваться в интеллектуальных системах поддержки принятия решений при медицинских диагностических видах деятельности. Использование таких систем однозначно повысит качество диагностики ВПС, уменьшит общее время обследования, что в конечном итоге приведёт к повышению доступности высокоспециализированной медицинской помощи.

Список литературы

1. Ассоциация сердечно-сосудистых хирургов России. Клинические рекомендации. Дефект межпредсердной перегородки. – 2018. – 34 с.
2. Купряшов, А. А. Дефект межпредсердной перегородки. Частичный аномальный дренаж легочных вен / А. А. Купряшов // Детская кардиохирургия. – 2016. – С. 294 – 312.
3. Молокович Г. Н. Особенности эхокардиографических показателей у детей с врожденными пороками сердца при задержке внутриутробного развития :дис. – ГОУДПО" Казанская государственная медицинская академия", 2007.
4. Сахарчук, Т. В. Внутриутробные предпосылки формирования дефектов межпредсердной перегородки. / Т. В. Сахарчук. // Современная морфология: проблемы и перспективы развития. – 2019. – С. 84 – 86.
5. Цибулькин Н.А., Самигуллина Д.Н., Молокович С.С. Особенности внутрисердечной гемодинамики при дефекте межпредсердной перегородки в первый месяц жизни // ПМ. 2016. №9 (101).

РЕШЕНИЕ ЗАДАЧИ КЛАССИФИКАЦИИ С ИСПОЛЬЗОВАНИЕМ СЕГМЕНТНОЙ СПАЙКОВОЙ МОДЕЛИ НЕЙРОНА НА ПЛИС

Т.Т.Исаков^{1,3}, А.В.Бахшиев^{1,2}, А.М. Корсаков³

¹ Санкт-Петербургский политехнический университет Петра Великого,

bakhshiev_av@spbstu.ru

² ООО Системы Компьютерного Зрения

³ Центральный научно-исследовательский и опытно-конструкторский институт

робототехники и технической кибернетики

t.isakov@rtc.ru

Введение

На сегодняшний день нейронные сети благодаря впечатляющим результатам активно используются в самых разных отраслях жизни. Однако их дальнейшее развитие затруднено из-за различных ограничений. Одним из главных ограничений является низкая энергоэффективность нейронных сетей, что является проблемой при их встраивании в автономные системы. Решением этой и других проблем нейронных сетей занимаются ученые из области спайковых нейронных сетей, в основе которых лежат более биоподобные модели нейронов. Одним из главных отличий таких сетей от традиционных является то, что спайковые нейроны обмениваются не действительными числами а спайками (единичными импульсами). Принцип работы нейронных сетей, построенных на спайковых моделях нейрона, подразумевает высокую степень асинхронности и параллельности работы сети, что трудно выполнимо на существующих CPU или даже GPU. По этой причине разрабатываются специализированные вычислители для работы со спайковыми нейронными сетями, такие как TrueNorth [1], SpiNNaker [2], Loihi [3], Tianjic [4]. Однако данные вычислители либо недоступны, либо способны воспроизводить очень ограниченный набор существующих спайковых моделей

³ Работа проводилась в рамках выполнения в ЦНИИ РТК государственного задания Минобрнауки России на 2023 год: “Исследование и разработка биоподобной системы управления поведением мобильных роботов на базе энергоэффективных программно-аппаратных нейроморфных средств” (FNRG-2022-0016 1021060307690-3-1.2.1;2.2.2).

нейрона. Отличной альтернативой для исследователей является использование ПЛИС для реализации своих собственных моделей и архитектур. На данный момент существует большое количество реализаций различных моделей нейрона: LIF [5,6,8], SRM [7], SRM0 [9], Ижикевич [10], Ходжкин-Хаксли [11]. Существуют также работы по решению посредством ПЛИС задач распознавания образов (pattern recognition) [5,12], распознавания символов (character recognition) [13], управления (control) [14], а также генерации паттернов (pattern generation) [15,16].

Модели, учитывающие структуру нейрона, называют сегментными моделями (compartmental). На данный момент можно выделить несколько вариантов сегментных моделей: двухсегментную модель [17], состоящую из модулей сомы и дендритов, трехсегментную модель [18], состоящую из модулей сомы, апикальных и базальных дендритов и CSNM модель [19], состоящую из модулей синапсов, ионного механизма, описывающего участки дендритов, и сомы с низкороговой зоной. В работе [20] демонстрируется, что многосегментные модели нейрона, реализованные на нейроморфных чипах, позволяют имитировать динамические процессы нейронных цепей мозга при низких энергозатратах. Однако сегментные модели нейрона могут также использоваться и для решения практических задач.

В работе [14] предлагается алгоритм обучения спайковой нейронной сети, использующей многосегментные нейроны для обработки данных о состоянии системы. Данная сеть управляет персонажем в компьютерных играх Atari, и благодаря использованию сегментных нейронов имеет значительный прирост игровых очков относительно других нейронных сетей, в том числе спайковых. Авторы делают вывод что сегментные модели играют большую роль в глубоком рас-пределенном обучении с подкреплением, что является важным основанием для дальнейшего развития сегментных моделей.

В работе [21] представлен алгоритм структурного обучения для решения задачи классификации. Данный метод имеет ряд преимуществ, так как для обучения может быть достаточно одного примера. Целью данной работы является

реализация на FPGA классификатора для данных IRIS [22] на основе CSNM модели нейрона. CSNM модель была выбрана, так как по сравнению с другими сегментными моделями она позволяет строить сложную структуру дендритного дерева а дальнейшее развитие алгоритма может позволить одновременно использовать и структурное и параметрическое обучение. Полученная реализация позволит выполнять моделирование спайковых нейронных сетей на сегментных моделях нейрона в реальном времени или даже быстрее.

2. Сегментная спайковая модель нейрона

Как уже было сказано выше, сегментные модели учитывают структуру дендритного дерева. Модель описывается некоторой системой дифференциальных уравнений, подробное описание которой представлено в работе [19]. Для решения данной системы используется метод преобразования Эйлера.

Согласно модели, входные сигналы поступают на синапсы, отражающие влияние синаптического сотка на сегмент мембраны нейрона. Поведение синапсов моделируется с помощью полученной после преобразований системы (начальные условия $\rho(0) = 0$):

$$\left. \begin{aligned} \rho_i &= \rho_{i-1} + h \left(\frac{x - \rho_{i-1}}{T_s} \right) \\ T_s(t) &= \begin{cases} \tau_s, & x(t) > 0 \\ \tau_d, & x(t) \leq 0 \end{cases} \\ i_s &= \rho \frac{\varepsilon_s}{R_s} \omega \end{aligned} \right\}, \quad (1)$$

где ρ – характеризует условную концентрацию медиатора, выделившегося в ответ на импульс,

h – шаг интегрирования,

T_s – постоянная времени выделения или распада медиатора,

R_s – сопротивление синапса,

ε_s – электродвижущая сила синаптической передачи,

ω – вес связи,

i_s – выходной синаптический ток.

Значения синаптического тока подаются на сегменты мембраны. Ионные механизмы, описывающие деполяризацию и гиперполяризацию мембраны моделируются с помощью системы (начальные условия $U(0) = 0$):

$$\left. \begin{aligned} U_i &= U_{i-1} + h \left(\frac{U_\Sigma - U_{i-1}(1 + g_\Sigma R_m)}{T_I} \right) \\ T_I &= \frac{C_m}{g_\Sigma + R_m^{-1}} \end{aligned} \right\} \quad (2)$$

где U_i – вклад сегмента в величину внутриклеточного потенциала,

h – шаг интегрирования,

R_m – сопротивление ионного механизма,

C_m – емкость ионного механизма,

g_Σ – суммарная проводимость моделей активных синапсов.

U_Σ – ожидаемый вклад сегмента в величину внутриклеточного потенциала при отсутствии внешнего возбуждения, которая определяется активностью предыдущих сегментов мембраны

Выходы сегментов мембраны на теле нейрона (сома) суммируются и подаются на генератор выходного сигнала, имеющий некоторый порог срабатывания. Если нейрон срабатывает, на входы сегментов на теле нейрона подается тормозящий сигнал, что позволяет моделировать рефрактерный период.

3. Аппаратная реализация CSNM модели на ПЛИС

Решение дифференциальных уравнений напрямую требует большого количества вычислительных ресурсов. Ресурсы ПЛИС ограничены, поэтому создание нейронных сетей большого объема в таком случае проблематично. Решения дифференциальных уравнений, описывающих спайковые нейронные сети, включают в себя ядра с экспоненциальной временной зависимостью. Существуют различные варианты аппроксимации таких экспоненциальных функций, направленные на определенную точность и вычислительные затраты. В данной работе используется аппроксимация похожая на методы base-2 и CORDIC, так как операции умножения и деления заменяются на сдвиги и операции сложения. Важ-

ным отличием является то, что для полученной модели не нужно использовать память, что позволяет сохранить ресурсы ПЛИС. Также вычисления с плавающей запятой приведены к целочисленным вычислениям, что также экономит ресурсы ПЛИС. Минусом такого подхода является подбор диапазонов значений рассматриваемых величин и констант. Также из-за использования сдвигов теряется гибкость настройки модели, однако на данном этапе это не является проблемой.

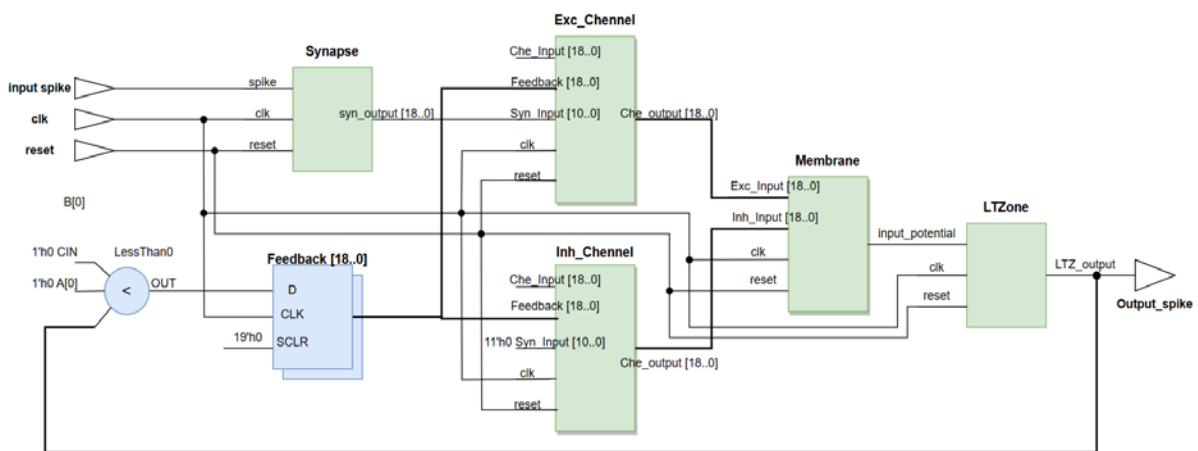


Рис.2. RTL-схема сегментной модели нейрона.

Логика ПЛИС позволяет детально аппаратно реализовать сегментную модель нейрона. На рисунке 2 представлена RTL-схема сегментной модели нейрона. Для работы модели используются 3 входа: **clk**, регулирующий синхронную работу элементов; **reset**, обнуляющий значения блоков при запуске; **input spike**, отвечающий за входной сигнал нейрона. Входной сигнал передается в блок **Synapse**, реализующий динамику, описанную в системе уравнений (1). Значения, генерируемые синапсов, передаются в возбуждающий канал **Exc_Channel** (динамика описана в системе уравнений (2)). В данной реализации на блок **Inh_Channel**, моделирующий тормозный ионный механизм, сигнал с синапса не подается. Выходы возбуждающего и тормозного канала передаются в блок **Membrane**, внутри которого эти значения суммируются. Как только выход блока мембраны **input potential** становится больше порога в блоке **LTZone**, описывающего низкороговую зону, нейрон выдает выходной спайк **Output spike**. Вме-

сте с этим запускается обратная связь, которая записывает значение обратной связи в регистры **Feedback**. Обратная связь уменьшает проходимость сигнала от синапса через ионные механизмы, из-за чего нейрон некоторое время перестает выдавать выходной спайк. Полученная схема полностью описывает цикл работы сегментной спайковой модели нейрона.

Таблица 1. Сравнение полученной реализации CSNM модели со связанными работами

Модель	FF (регистры) + LUT (логические элементы)	DS P	Количество нейронов	Память	Среднеквадратичное отклонение
LIF model (2011) [5]	14098 + 22815	-	648	126Kb (BRAM)	-
LIF model (2020) [6]	135 + 218	-	1	15Kb (-)	0,0015
SRM model (2012) [7]	202 + 378	-	1	-	-
LIF model (2006) [8]	4581	-	1,024	320Kb (BRAM)	-
SRM0 model (2020) [9]	296 + 314	4	512	1,003x64b (DRAM)	$4 * 10^{-12}$ - $1 * 10^{-10}$
CSNM (Данная работа)	67 + 245 (16607)	-	1(3)	-	0,004 – 0,01

Таким образом, используя описанные модули и добавляя блоки ионных механизмов можно построить сегментную модель нейрона любой сложности,

ограничиваясь только ресурсами ПЛИС. В таблице 1 представлено сравнение полученной реализации CSNM модели с другими реализациями спайковых моделей нейронов в ПЛИС. Реализации сравниваются по количеству используемых ресурсов ПЛИС, количеству реализованных нейронов и среднеквадратичному отклонению реализации.

По значениям, представленным в таблице, можно сделать вывод, что модель имеет конкурентные показатели используемых ресурсов. Стоит отметить, что количество ресурсов, занимаемое нейроном, сильно зависит от структуры самого нейрона. Для сравнения, в таблице указаны ресурсы, используемые для одного базового необученного нейрона, а в скобках для 3 нейронов, обученных на данных IRIS [22]. В дальнейшем планируется использование памяти, что позволит сэкономить ресурсы ПЛИС при масштабировании моделей.




Рис.3. Схема построенного классификатора.

4. Классификатор данных IRIS

С помощью среды NeuroModeler⁴ на трех примерах (по одному для каждого класса) из данных IRIS [22] была обучена модель классификатора. Полученная схема (рисунок 3) из трех нейронов была реализована в ПЛИС на чипе Cyclone IV EP4CE22F17C6N с 22.320 логическими элементами. В данных IRIS рассматриваются 4 признака, которые преобразуются во входные паттерны нейронов. Также дополнительно используется калибровочный сигнал, чтобы отличать оди-

наковые по форме, но различные по длительности паттерны. Обратная связь при срабатывании нейронов распространяется на все нейроны, чтобы избежать нескольких срабатываний. Таким образом «победителем» будет являться нейрон, испустивший спайк раньше.

Сравнение представленной реализации с другими решениями задачи классификации данных IRIS с использованием импульсных нейронов представлено в таблице 2. Для описания архитектур используется формат $N_i - N_h - N_o$, указывающий количество нейронов на входном, скрытом и выходном слоях модели. Модели SRESN и DoB имеют по 2 слоя, однако количество нейронов выходного слоя может варьироваться (значения в скобках). Реализация CSNM модели также двухслойная, однако в реализации, представленной в данной работе, используется только один слой из трех нейронов.

Таблица 2. Сравнение существующих спайковых классификаторов данных IRIS

Модель	Архитектура	Кол-во настраиваемых параметров	Точность (%)
SpikeProp (Bohte et al. 2002) [23]	25-10-3	4480	96,1
SWAT (Wade et al. 2010) [24]	24-312-3	936	95,3
SRESN (2016) [25]	24-(5-11)	120-264	97,0
DoB-SNN (2021) [26]	5-(5-8)	25-40	97,7
CSNM (2021) [21]	12-3	120	83,3
CSNM (Данная работа)	3	30	76,6

Из таблицы видно, что полученная модель имеет сравнительно низкие по-

⁴ <https://neuromodeler.ru/>

казатели точности. Снижение точности относительно оригинального эксперимента [23] вызвано упрощением модели с 15 до 3 нейронов для экономии ресурсов ПЛИС, а также аппроксимацией вычислений. Положительной стороной модели является относительно малое количество настраиваемых параметров. Другим важным достижением является скорость работы алгоритма. Реакция одного нейрона на компьютере посредством CPU измеряется в секундах или долях секунд (в зависимости от мощности CPU), в то время как реакция такого же нейрона на ПЛИС измеряется в долях миллисекунд. Таким образом в данной реализации мы получаем прирост в тысячу раз, что особо ощутимо при оценке относительно больших моделей на больших данных, что на CPU может занимать несколько суток. Стоит отметить, что на данном этапе обучение нейрона выполняется с помощью одного примера, что также отражается в низкой точности. Инкрементное обучение, позволяющее дообучать нейроны на нескольких примерах является одним из направлений текущих исследований.

5. Выводы и дальнейшая работа

В представленной работе рассматривается задача классификации данных IRIS с использованием сегментной спайковой модели нейрона, решение которой реализуется аппаратно на ПЛИС. Данное направление исследований является актуальным, так как для использования импульсных нейронных сетей и их встраивания в автономные системы требуются специализированные вычислители.

В ходе работы был построен классификатор, ресурсные характеристики которого не уступают схожим работам, а вычислительные характеристики превосходят таковые на CPU. Точность полученной модели ниже, чем в аналогичных работах, однако дальнейшие исследования в области инкрементного обучения и методов аппроксимации позволят увеличить точность. Также планируется использовать RAM в целях масштабирования моделей и оптимизации вычислений. Еще одним направлением дальнейших работ является реализация обучения на чипе как в целях ускорения тестирования моделей, так и для исследований

обучения с подкреплением.

Список литературы

1. Merolla P. A. et al. A million spiking-neuron integrated circuit with a scalable communication network and interface //Science. – 2014. – Т. 345. – №. 6197. – С. 668-673.
2. Van Albada S. J. et al. Performance comparison of the digital neuromorphic hardware SpiNNaker and the neural network simulation software NEST for a full-scale cortical microcircuit model //Frontiers in neuroscience. – 2018. – Т. 12. – С. 291.
3. Davies M. et al. Loihi: A neuromorphic manycore processor with on-chip learning //Ieee Micro. – 2018. – Т. 38. – №. 1. – С. 82-99.
4. Pei J. et al. Towards artificial general intelligence with hybrid Tianjic chip architecture //Nature. – 2019. – Т. 572. – №. 7767. – С. 106-111.
5. Caron L. C., Mailhot F., Rouat J. FPGA implementation of a spiking neural network for pattern matching //2011 IEEE International Symposium of Circuits and Systems (ISCAS). – IEEE, 2011. – С. 649-652.
6. Perez-Peña F., Cifredo-Chacon M. A., Quiros-Olozabal A. Digital neuromorphic real-time platform //Neurocomputing. – 2020. – Т. 371. – С. 91-99.
7. Rosado-Muñoz A., Bataller-Mompeán M., Guerrero-Martínez J. FPGA implementation of spiking neural networks //IFAC Proceedings Volumes. – 2012. – Т. 45. – №. 4. – С. 139-144.
8. Ros E. et al. Real-time computing platform for spiking neurons (RT-spike) //IEEE Trans. Neural Networks. – 2006. – Т. 17. – №. 4. – С. 1050-1063.
9. Kim J. et al. Hardware-efficient emulation of leaky integrate-and-fire model using template-scaling-based exponential function approximation //IEEE Transactions on Circuits and Systems I: Regular Papers. – 2020. – Т. 68. – №. 1. – С. 350-362.
10. Ambroise M. et al. Biorealistic spiking neural network on FPGA //2013 47th Annual Conference on Information Sciences and Systems (CISS). – IEEE, 2013. – С. 1-6.

11. Yaghini Bonabi S. et al. FPGA implementation of a biological neural network based on the Hodgkin-Huxley neuron model //Frontiers in neuroscience. – 2014. – Т. 8. – С. 379.
12. Nevarez Y. et al. Accelerator framework of spike-by-spike neural networks for inference and incremental learning in embedded systems //2020 9th International Conference on Modern Circuits and Systems Technologies (MOCASST). – IEEE, 2020. – С. 1-5.
13. Rice K. L. et al. FPGA implementation of Izhikevich spiking neural networks for character recognition //2009 International Conference on Reconfigurable Computing and FPGAs. – IEEE, 2009. – С. 451-456.
14. Sun Y. et al. Multi-compartment Neuron and Population Encoding improved Spiking Neural Network for Deep Distributional Reinforcement Learning //arXiv preprint arXiv:2301.07275. – 2023.
15. Donati E. et al. A spiking implementation of the lamprey's Central Pattern Generator in neuromorphic VLSI //2014 IEEE Biomedical Circuits and Systems Conference (BioCAS) Proceedings. – IEEE, 2014. – С. 512-515.
16. Rostro-Gonzalez H. et al. A CPG system based on spiking neurons for hexapod robot locomotion //Neurocomputing. – 2015. – Т. 170. – С. 47-54.
17. Urbanczik R., Senn W. Learning by the dendritic prediction of somatic spiking //Neuron. – 2014. – Т. 81. – №. 3. – С. 521-528.
18. Sacramento J. et al. Dendritic cortical microcircuits approximate the backpropagation algorithm //Advances in neural information processing systems. – 2018. – Т. 31.
19. Бахшиев А. В., Демчева А. А. Сегментная спайковая модель нейрона CSNM //Известия высших учебных заведений. Прикладная нелинейная динамика. – 2022. – Т. 30. – №. 3. – С. 299-310.
20. Kopsick J. D. et al. Robust resting-state dynamics in a large-scale spiking neural network model of area CA3 in the mouse hippocampus //Cognitive Computation. – 2022. – С. 1-21.

21. Astapova L. A. et al. Compartmental spiking neuron model for pattern classification //Journal of Physics: Conference Series. – IOP Publishing, 2021. – Т. 2094. – №. 3. – С. 032032.
22. UCI Machine Learning Repository: сайт. – URL: <https://archive.ics.uci.edu/ml/datasets/iris> (дата обращения: 24.08.2023)
23. Bohte S. M., Kok J. N., La Poutré J. A. SpikeProp: backpropagation for networks of spiking neurons //ESANN. – 2000. – Т. 48. – С. 419-424.
24. Wade J. J. et al. SWAT: A spiking neural network training algorithm for classification problems //IEEE Transactions on neural networks. – 2010. – Т. 21. – №. 11. – С. 1817-1830.
25. Dora S. et al. Development of a self-regulating evolving spiking neural network for classification problem //Neurocomputing. – 2016. – Т. 171. – С. 1216-1229.
26. Saranirad V. et al. DoB-SNN: A New Neuron Assembly-Inspired Spiking Neural Network for Pattern Classification //2021 International Joint Conference on Neural Networks (IJCNN). – IEEE, 2021. – С. 1-6.

КОНСТРУИРОВАНИЕ И РЕАЛИЗАЦИЯ ЭКСПЕРТНОЙ СИСТЕМЫ ПО ВАЛИДАЦИИ ПОЛЬЗОВАТЕЛЕЙ НА ОСНОВЕ ТЕКСТОВОГО СЛЕДА

А.О.Кириличев, Н.А.Болсуновский

Сибирский федеральный университет

Проблема экспертного анализа следов в сетевых приложениях, включая текстовые следы, является актуальной и сложной задачей. Экспертный анализ следов относится к процессу изучения и интерпретации информации, оставленной пользователями во время взаимодействия с сетевыми приложениями, включая текстовые сообщения, комментарии, посты в социальных сетях и т.д. Этот вид анализа может быть важным инструментом для различных целей, таких как обеспечение безопасности, выявление мошенничества и т.д.

Для решения этих проблем применяются различные методы и технологии, включая автоматическую обработку языка Natural Language Processing, Data Mining, экспертные (рекомендательные) системы. Эти инструменты помогают снизить нагрузку на экспертов, автоматизировать процесс анализа текстовых следов и обнаруживать необычные или подозрительные активности [1]. Но наиболее востребованным является анализ, позволяющий получить не только экспертную оценку, но и возможность обосновать полученный вывод.

Анализ текстового следа представляет собой процесс изучения и интерпретации этой информации с целью извлечения полезной информации, выявления паттернов, классификации текстов и выявления смысла [2]. Рассмотрим описанную проблему на примере электронного обучения, реализуемого через онлайн-платформу (например, системы класса Intelligence Tutoring Systems). Текстовый след, который оставляет пользователь при взаимодействии с учебной платформой, содержит ценную информацию о его индивидуальных характеристиках, способностях и стиле общения. Анализ этого следа позволяет выявить особенности исследуемого пользователя. При сравнении текстовых следов разных пользователей или одного и того же пользователя возникает возможность выявления подмены, то есть ситуации, когда другой человек представляет себя

как валидный пользователь платформы.

Выявление подмены пользователя является критическим аспектом в процессе оценки знаний и навыков студентов. Данный процесс позволяет предотвратить недобросовестные практики, такие как использование посторонней помощи или привлечение внешних информационных систем и инструментов. Правильная валидация пользователя по текстовому следу способствует объективности оценки, повышает качество образования и обеспечивает достоверность полученных результатов в процессе и итоговых испытаний.

Существуют различные методы валидации пользователя в рамках учебного процесса, помимо анализа текстового следа. Однако, у каждого из этих методов есть свои недостатки, которые ограничивают их эффективность и применимость. Например, логин и пароль могут быть скомпрометированы или переданы третьему лицу намеренно с целью подмены одного пользователя более компетентным для успешного прохождения итоговых испытаний, методы идентификации по биометрическим данным требуют наличие специализированного, дорогостоящего оборудования, такого как сканер отпечатков пальцев или систему распознавания лиц, некоторые методы биометрической идентификации могут быть подвержены ложным срабатываниям или отказам при распознавании, особенно в условиях с низким качеством оборудования или изменениями в физических характеристиках пользователя.

Несмотря на присутствие этих методов валидации, более глубокий анализ текстового следа предлагает дополнительные преимущества, такие как широкий спектр информации о стиле письма и характеристиках пользователя, а также возможность принятия решений в реальном времени без необходимости дополнительного оборудования или сложных процедур идентификации. Формирование последовательности текстовых цифровых следов быть использован для верификации пользователя на последующих шагах взаимодействия с информационной системой [3].

Целью данной работы является разработка методики сбора и анализа текстового следа в сетевых приложениях с целью обеспечения безопасности и вы-

явления мошенничества. В рамках работы предусмотрены задачи по разработке нового метода динамической валидации пользователя на основе текстового следа с помощью экспертной системы; реализация метода на базе экспертной системы; проведение экспериментальной оценки для реальных данных образовательного цифрового следа.

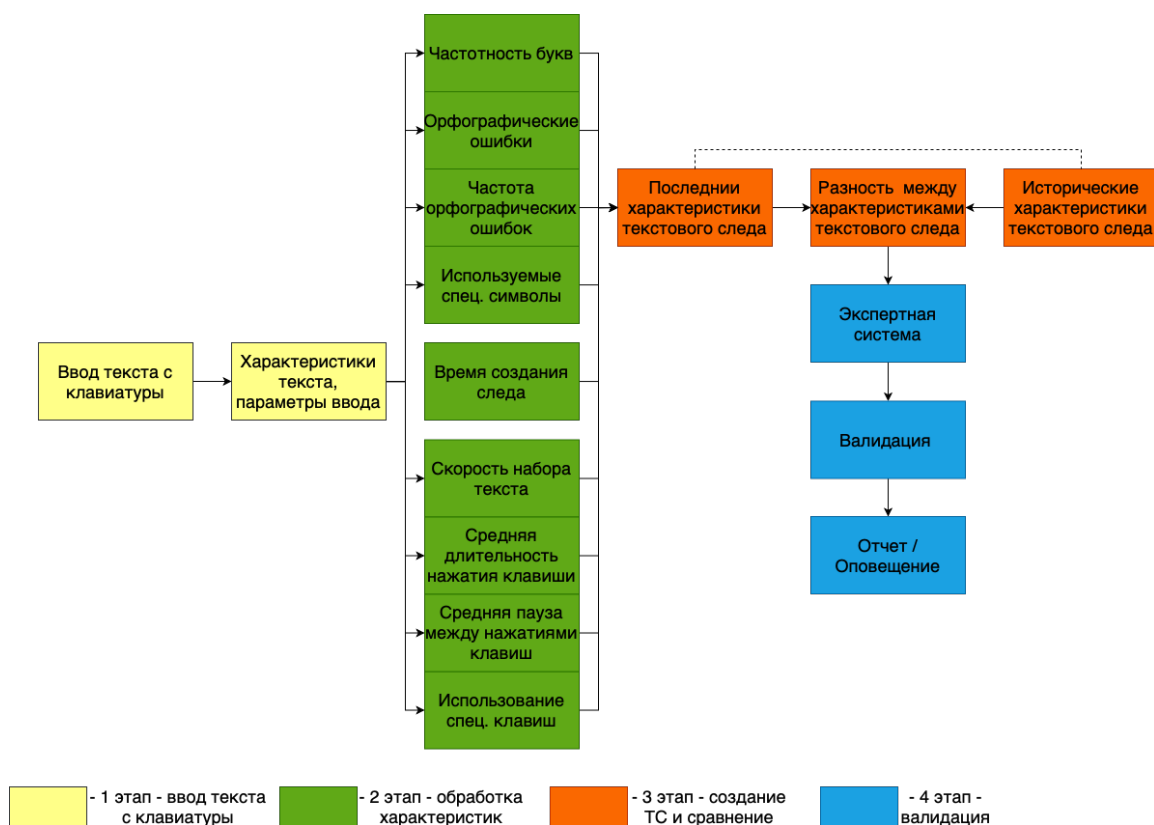


Рис.1. Этапы методики валидации пользователя по текстовому следу.

Основной принцип работы предлагаемой нами методики динамической валидации пользователя заключается в том, что из вводимых с клавиатуры текстов извлекаются данные, которые анализируются, параметризуются, сравниваются с сохраненными ранее данными из профиля и на их совокупности делается вывод о степени достоверности валидации. За каждый из этих этапов отвечают специальные модули, которые и производят анализ параметров пользовательской активности, таких как фиксация эмпирических закономерностей распределения частотности слов и букв, фиксация орфографических и пунктуационных ошибок в тексте, фиксация используемых специальных символов употребляемых пользователем в тексте, фиксация скорости набора текста с клавиатуры, фиксация ис-

пользуемых специальных клавиш при наборе текста на клавиатуре и другие факторы. Эти параметры сравниваются с историческими значениями, предварительно сохраненными в базе данных, для определения соответствия пользовательской активности легитимному пользователю или злоумышленнику.

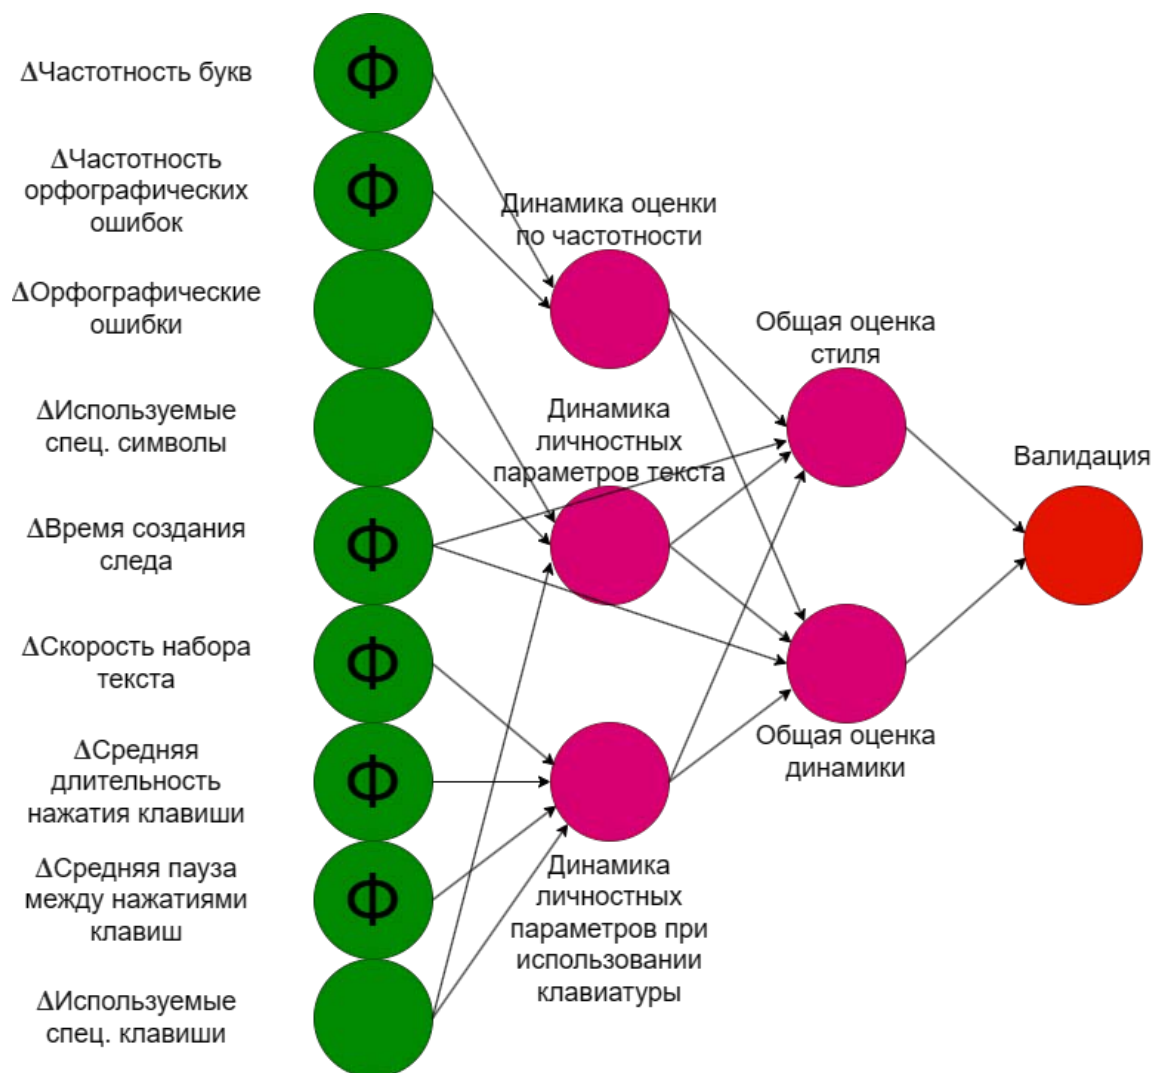


Рис.2. Граф решений в FLM_Builder.

Этап валидации базируется на продукционной экспертной системе, база знаний которой реализована в flm-формате (приложение FLM_Builder v 4.1b [4]). На рис. 2 приведен граф решений. Он состоит из входов, на которые подаются характеристические значения текстового следа, такие как эмпирическая закономерность распределения частотности слов и букв, орфографические и пунктуационные ошибки в тексте, и другие, 5 промежуточных гипотез, которые основаны на базе знаний (105 правил) и выходных параметрах [5]. Некоторые характе-

ристики (обозначены буквой «Ф») предварительно подвергаются фазификации (метод нечёткой логики Л. Заде [6]).

Описанная экспертная система интегрирована в приложение, которое реализует центральную функцию методики валидации пользователя по текстовому следу. Это оконное приложение, которое обеспечивает проверку подлинности пользователя на основе анализа его текстового следа (написано на языке программирования Python). Приложение имеет окно с многострочным полем ввода, где пользователь может вводить ответы на практические задания или вопросы, требующие развернутого текстового ответа. Введенный пользователем текст обрабатывается алгоритмом, который преобразует текстовые характеристики в текстовый след пользователя. Приложение накапливает эталонный текстовый след пользователя в процессе его взаимодействия с системой. Это может быть достигнуто путем сохранения и агрегации текстовых следов пользователя, полученных из различных заданий или сессий [5]. При достижении определенного объема эталонного текстового следа, проводится валидация пользователя.

Приложение может быть интегрировано с другими системами, для обеспечения более широкой проверки подлинности пользователя и предотвращения подмены одного пользователя другим. Такое приложение может быть полезно при дистанционной форме обучения или в других ситуациях, где необходимо обеспечить достоверность и подлинность пользователя на основе его текстового следа. Оно позволяет автоматизировать процесс проверки подлинности и предотвращает возможность мошенничества с использованием подмены пользователей.

Предложенная методика была испытана в ходе эксперимента по обучению магистрантов в Сибирском федеральном университете. В результате были получены и проанализированы данные о текстовом следе каждого участника эксперимента. На рис. 3 приведена гистограмма, по которой четко видно разделение текстовых следов пользователей по следующим классам сравнения:

– сравнение двух текстовых следов одного и того же пользователя на различных этапах процесса обучения (синие ромбы);

– сравнение текстовых следов разных пользователей с одного этапа обучения (красные квадраты).




Рис.3. Сравнительный анализ текстовых следов.

По данным с рис. 3, можно сделать вывод, что, основываясь на решениях экспертной системы, можно различать пользователей друг от друга по текстовому следу (включая выявление подмены).

Применение методики валидации пользователя по текстовому следу в процессе дистанционного обучения имеет значительный потенциал. Она может быть использована для существенного снижения вероятности перехвата удаленного управления информационной системой и подмены пользователя более осведомленным лицом при прохождении аттестационных заданий. По аналогии, в обучающих системах могут быть реализованы решения для более сложных задач (например, генерации объяснений действиям обучающей системы [7] или адаптации состава учебного материала [8]).

Дальнейшее развитие исследования может включать расширение методики валидации пользователя по текстовому следу для других областей применения, а также улучшение ее алгоритмов и адаптацию под различные типы текстовых данных.

Список литературы

1. Орлов А.И. Экспертные оценки //Организационно-экономическое моделирование. — Москва: МГТУ им. Н.Э. Баумана. — 2009. — С.15 – 40.
2. Наумов В.В. Лингвистическая идентификация личности. — Москва: Ленанд. — 2022. — С.144 – 155.
3. Гальперин И.Р. Текст как объект лингвистического исследования — Москва: КомКнига, — 2006. — С. 36 – 42.
4. Болсуновский Н.А., Пронин А.Д., Углев В.А. Конструктор продукционных экспертных систем с элементами нечёткой логики FLM_Builder и интеграция его моделей в пользовательские проекты //Нейроинформатика, ее приложения и анализ данных: XXX Всероссийский семинар. — Красноярск: ИВМ СО РАН. — 2022. — С. 24-33.
5. Кириличев А.О., Углев В.А. База знаний для системы валидации пользователей по текстовому следу //Актуальные научные исследования: сборник статей XII Международной научно-практической конференции. В 4 ч. Ч. 2. — Пенза: МЦНС «Наука и Просвещение». — 2023. — С. 73 – 76.
6. Zadeh L. Fuzzy Sets. Information and Control, 8(3), June 1965. – pp. 338-353.
7. Uglev V.A. Explanatory Didactic Dialogue in the Intelligent Tutoring Systems Based on the Cross-Cutting Approach // Proc. Augmented Intelligence and Intelligent Tutoring Systems. ITS 2023. LNCS, vol. 13891. Springer, Cham. DOI 10.1007/978-3-031-32883-1_34.
8. Углев В.А. Реализация механизма принятия решений в интеллектуальной автоматизированной обучающей системе на базе модуля экспертных систем // XXI национальная конференция по искусственному интеллекту с международным участием (КИИ-2023). — Смоленск: Изд-во МЭИ, 2023 (в печати).

ДВУМЕРНОЕ СПЕКТРАЛЬНОЕ ПРЕОБРАЗОВАНИЕ УОЛША В СИСТЕМАХ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА КЛАССИФИКАЦИИ УЛЬТРАЗВУКОВЫХ ИЗОБРАЖЕНИЙ⁵

А.А. Кузьмин¹, Часиб Хасан Аль- Дарраджи², С.А. Филист¹, А.Ю. Сухомлинов¹

¹Юго-Западный государственный университет,
кафедра биомедицинской инженерии, *SFelist@gmail.com*

² Университет Дияла Баакубу, Республика Ирак

Ультразвуковые (УЗ) изображения относятся к сложным неструктурированным изображениям с большим уровнем помех с очень малым соотношением полезный сигнал/шум [1]. Основными задачами автоматизированных систем обработки УЗ изображений являются повышение соотношения сигнал/шум, поиск объектов на картинах и измерение характеристик объектов (количество объектов, размеры, яркость и т.п.) [2, 3, 4, 5]. Для повышения соотношения сигнал/шум в технике применяют фильтры, которые целенаправленно изменяют спектр обрабатываемого сигнала – полезные частотные составляющие фильтры пропускают, а частотные составляющие помех фильтры подавляют.

Для фильтрации частот и различных частотных преобразований в сигналах, в том числе и двумерных сигналах, используют частотные преобразования, такие как преобразование Фурье, Хартли, Уолша и т.п.. Преобразование Уолша выгодно отличается от вышеприведенных преобразований тем, что функции Уолша представляют собой последовательности единичных импульсов с единичной (возможно, как положительной, так и отрицательной) полярностью. Для вычисления преобразования Уолша нет нужды в вычислениях тригонометрических функций, что приводит к существенному увеличению быстродействия систем на их основе. Так, по нашим данным, вычисление двумерного преобразования Уолша в окне 8x8 пикселей на обычном учебном компьютере с процессором Celeron 2ГГц занимает время менее микросекунды. Это означает, что если для каждого пикселя мегапиксельного изображения посчитать свое двумерное пре-

⁵ Работа выполнена в рамках реализации программы развития ФГБОУ ВО «Юго-Западный государственный университет» программы стратегического академического лидерства «Приоритет-2030»

образование Уолша, то суммарное время займет менее секунды. Это вполне допустимое время даже для обработки изображения в реальном времени.

Для построения систем обработки изображений на базе спектрального двумерного преобразования Уолша следует изучить свойства двумерных частот Уолша. Например, нулевая частота (частота с координатами 0,0) судя по формуле преобразования Уолша [6] представляет собой среднее арифметическое яркости пикселей в окне преобразования. Для обработки УЗ изображений это очень важное знание, так как известно, что целый ряд объектов на УЗ-изображениях обладают определенной эхогенностью. Визуально эхогенность воспринимается как яркость точки УЗ-картины.

Частота с координатой 1,0 отвечает за вертикальные границы (см. рисунок 1). На этом рисунке показан вертикальный перепад яркости с максимального значения до минимального значения, который происходит ровно посередине (при $x=0.5*\max=\text{const}$) окна (рисунок 1а). Этой картине соответствуют значения частот Уолша, приведенные на рисунке 1в в цифрах (приведен модуль чисел) и на 1б в полутоновом виде. Если бы перепад яркости происходил не ровно посередине изображения, то тогда в остальных частотах, отличных от 0,0 и 1,0 появились бы ненулевые числа, соответствующие фазовым искажениям. Однако общая полутоновая картина не сильно изменилась бы и доминирующие частоты 0,0 и 1,0 сохранили бы свое положение. Такая же картина наблюдалась бы и при замене ровной вертикальной линии плавной дугой, например, от вертикальной части круга – при вертикальном характере границы перехода доминирует частота с координатой 1,0 (рисунок 2). При инверсной входной картине, когда происходит вертикальный перепад яркости с минимального значения до максимального значения, который происходит ровно посередине окна, значения частот Уолша будут теми же, но с отрицательным знаком. Поэтому знак в числах рисунка 1б отброшен и приведены только амплитуды частот.




Рис. 1. – Вертикальный перепад яркости (а) и его преобразование Уолша полутоновое (б) и в цифрах (в)




Рис. 2. – Неровный вертикальный перепад яркости (а) и его преобразование Уолша полутоновое (б) и в цифрах (в)

Аналогично частоте с координатой 0,1, частота с координатой 1,0 отвечает за горизонтальные границы (см. рисунок 3).




Рис. 3. – Горизонтальный перепад яркости (а) и его преобразование Уолша полутоновое (б) и в цифрах (в)

На этом рисунке показан горизонтальный перепад яркости с максимального значения до минимального значения, который происходит ровно посередине окна, при $y=0.5*\max=\text{const}$ (рисунок 3а). Этой картине также соответствуют значения частот Уолша, приведенные на рисунке 3в в цифрах (приведен модуль чисел) и на 3б в полутоновом виде. Можно привести аналогичные рассуждения при фазовых сдвигах входной картины, а также при «неровностях» линий. И можно сделать аналогичный вывод: при горизонтальном характере границы перехода яркостей изображения доминирует частота с координатой 0,1.

Таким образом, анализ трех частот преобразования Уолша в окне может приводить к распознаванию нескольких состояний каждого конкретного пикселя: пиксель может принадлежать области с определенной (пониженной, средней, повышенной) экзогенностью, пиксель может быть границей вертикального или горизонтального перехода экзогенности. Для принятия решений при обработке изображений, в том числе и ультразвуковых, широко используются нейронные сети [7, 8, 9, 10]. В своей работе мы тоже используем работу нейронной сети, на входы которой будем подавать значения частот преобразования Уолша, а с выхода будем снимать числовые данные, соответствующие решениям о состоянии каждого пикселя (рис. 4). Архитектура нейронной сети может быть упрощена до одного-двух нейронов и тогда процесс обучения такой сети сводится к правильному установлению уровней порогов.

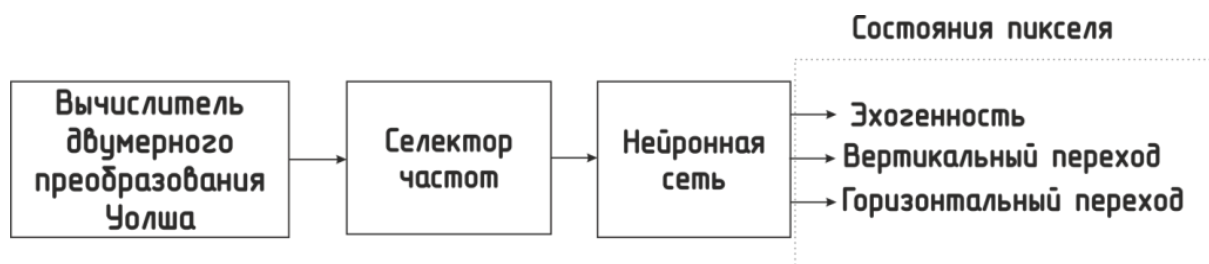


Рис. 4. – Архитектура детектора состояния пикселя на основе оконного двумерного преобразования Уолша

Для иллюстрации работы детектора вертикального края сформируем тестовое изображение, содержащее прямоугольник, наклонный прямоугольник и круг (рисунок 6а).




Рис. 51. - Работа детектора вертикального края: а) – исходное модельное изображение, б) – результат работы детектора

Выберем размер окна преобразования Уолша размером 8×8 пикселей и настроим нейронную сеть на частоту с координатой $1,0$. Последовательно для каждого пикселя исходного изображения взвесим квадратное окно размером 8×8 из пикселей правее и ниже от исходного пикселя. В этом окне находим преобразование Уолша и значение частоты с координатой $1,0$ передадим на нейронную сеть, которая в данном случае, играет роль амплитудного детектора. Результат работы нейронной сети приведен на рисунке 5б. Как мы видим на этом рисунке, вертикальные перепады яркости детектируются, а горизонтальные (верхняя и нижняя грани прямоугольника, а также верхняя и нижняя точки круга) нет. Аналогично можно сделать детектор горизонтальных перепадов яркости, но на частоте $0,1$ двумерного преобразования Уолша. Результат работы такого детектора приведен на рисунке 6. Выводы можно сделать аналогичные, но для горизонтальных перепадов яркости. Наконец, если сделать объединение работы двух вышеприведенных детекторов и на вход объединенной нейронной сети подать две частоты с координатами $1,0$ и $0,1$, то можно получить общий детектор края объектов на изображении. В этом случае объединенная нейронная сеть играет фактическую роль сумматора. Результат работы такого детектора на модельных данных приведен на рисунке 7.




Рис. 6. - Работа детектора горизонтального края: а) – исходное модельное изображение, б) – результат работы детектора




Рис. 7. - Работа детектора края на двух частотах: а) – исходное модельное изображение, б) – результат работы детектора

Реальные УЗ-изображения, например, брюшной полости характеризуются достаточно большой зашумленностью. Для визуального поиска объектов на изображении, а также для задач автоматизированных измерений исходное изображение необходимо избавить от шума, т.е. повысить соотношение сигнал/шум.

В качестве полезного сигнала очень часто используют границы объектов, поэтому поиск границ объектов можно рассматривать как процедуру фильтрации нежелательных помех. На рисунке 8а приведено УЗ-изображение поджелудочной железы. Применение разработанного детектора края на УЗ-изображении поджелудочной железы показано на рисунке 8б. Как видим из этого рисунка, края объектов органов брюшной полости выделяются, что приводит к улучшению визуального восприятия изображения, а также облегчает автоматизированные измерения на УЗ-изображении.



а)

б)

Рис. 8. – УЗ-изображение брюшной полости: а) – исходное изображение, б) – результат работы детектора краев

Полученные результаты применения разработанного детектора края на УЗ-изображении были сравнены с известными методиками поиска краев на изображении: с оператором Собеля, Шарра, Превитта[11]. С математической и практической точки зрения эти методики схожи с предложенным методом, но в них вместо пространственных функций Уолша первого порядка применяются базисные ядра Собеля, Шарра, Превитта с разными весовыми коэффициентами, причем как правило размерностью 3x3. Так как в предложенном методе присутствует нейронная сеть с пороговой обработкой, то можно сделать вывод, что разработанный детектор края включает в себя постобработку изображения, что приво-

дит к получению более контрастных результатов. Результаты работы разработанного детектора близки к методу Кэнни (Canny) [12], в котором используется фильтр Гаусса, оператор Собеля и гистерезисная пороговая постобработка. Результаты качества сильно зависят от правильно установленных уровней порогов что в нашем случае, что в случае применения методики Кэнни.

Проведены предварительные исследования вычислительной емкости локального двумерного преобразования Уолша для автоматизированных систем обработки медицинских УЗ изображений. На спектральной двумерной плоскости выделены частоты, анализ которых позволяет определять степень эхогенности в области сканирования, а также детектировать края объектов ультразвукового изображения. Предложена архитектура детектора состояния пикселя УЗ изображения на основе сканирующего оконного двумерного преобразования Уолша, селектора значимых частот и нейронной сети, которая настроена на классификацию состояния пикселя. Проведены испытания детектора как на модельных изображениях, так и на ультразвуковых изображениях фантомов и реальных медицинских ультразвуковых исследований брюшной полости человека. Сравнение предложенного детектора состояния пикселя УЗ изображения на основе сканирующего оконного двумерного преобразования Уолша с существующими методиками показали хорошие результаты при умеренной вычислительной нагрузке на ЭВМ.

Список литературы

1. Филист С.А., Томакова Р.А., Шаталова О.В., Кузьмин А.А., Али Кассим К.Д. Метод классификации сложноструктурируемых изображений на основе самоорганизующихся нейросетевых структур. Радиопромышленность. 2016;4:57-65.
2. Săftoiu A., Vilmann P., Gorunescu F., Janssen J., Hocke M., Larsen M., Iglesias-Garcia J., Arcidiacono P., Will U., Giovannini M., Dietrich CF., Havre R., Gheorghie C., McKay C., Gheonea DI., Ciurea T. Efficacy of an artificial neural network-based approach to endoscopic ultrasound elastography in diagnosis of focal pancre-

- atic masses. *Clinical Gastroenterology and Hepatology: the Official Clinical Practice Journal of the American Gastroenterological Association*. 2012;10(1):84-90. DOI: 10.1016/j.cgh.2011.09.014.
3. Ozkan M., Cakiroglu M., Kocaman O., Kurt M., Yilmaz B., Can G., Korkmaz U., Dandil E., Eksi Z. Age-based computer-aided diagnosis approach for pancreatic cancer on endoscopic ultrasound images. *Endoscopic Ultrasound*. 2016;5(2):101. DOI: 10.4103/2303-9027.180473.
 4. Tian G., Xu D., He Y., Chai W., Deng Z., Cheng C., Jin X., Wei G., Zhao Q., Jiang T. Deep learning for real-time auxiliary diagnosis of pancreatic cancer in endoscopic ultrasonography. *Frontiers in Oncology*. 2022;12:973652. DOI: 10.3389/fonc.2022.973652.
 5. Udriștoiu A.L., Cazacu I.M., Gruionu L.G., Gruionu G., Iacob A.V., Burtea D.E., Ungureanu B.S., Costache M.I., Constantin A., Popescu C.F., Udriștoiu Ș., Săftoiu A. Real-time computer-aided diagnosis of focal pancreatic masses from endoscopic ultrasound imaging based on a hybrid convolutional and long short-term memory neural network model. *PloS one*. 2021;16(6):e0251701. DOI: <https://doi.org/10.1371/journal.pone.0251701>.
 6. Голубов Б.И., Ефимов А.В., Скворцов В.А. Ряды и преобразования Уолша: Теория и применения. Изд. 2, испр. и доп. 2008. 352 с. ISBN 978-5-382-00611-6.
 7. Кудрявцев П.С., Кузьмин А.А., Филист С.А. Развитие методологии бустинга для классификации флюорограмм грудной клетки. *Биомедицинская радиоэлектроника*. 2016;9:10-15.
 8. Кудрявцев П.С., Кузьмин А.А., Савинов Д.Ю., Филист С.А., Шаталова О.В. Моделирование морфологических образований на рентгенограммах грудной клетки в интеллектуальных диагностических системах медицинского назначения. *Прикаспийский журнал: управление и высокие технологии*. 2017;(3):109-120.
 9. Филист С.А., Али Кассим К.Д., Кузьмин А.А., Шаталова О.В., Алябьев Е.А. Формирование признакового пространства для задач классификации сложно-

структурируемых изображений на основе спектральных окон и нейросетевых структур. Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2016;(4):56-68.

10. Филист С.А., Дабагов А.Р., Томакова Р.А., Малютина И.А., Кондрашов Д.С. Многослойные морфологические операторы для сегментации сложно-структурируемых растровых полутоновых изображений. Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2019;9(3):44-63.
11. Scott Krig, Computer Vision Metrics. Survey, Taxonomy and Analysis of Computer Vision, Visual Neuroscience, and Deep Learning. Springer Cham, 2016 - 637p. DOI: 10.1007/978-3-319-33762-3.
12. Canny J. A Computational Approach to Edge Detection. IEEE Transactions On Pattern Analysis And Machine Intelligence, Vol. Pami-8, No. 6, November 1986.

МЕТОД ВЫРАБОТКИ СТРАТЕГИИ ПОВЕДЕНИЯ ПРИ ПЕРЕГОВО- РАХ ИСКУССТВЕННЫХ ГЕТЕРОГЕННЫХ ИНТЕЛЛЕКТУАЛЬНЫХ АГЕНТОВ РЕФЛЕКСИВНО-АКТИВНЫХ СИСТЕМ⁶

С.В.Листопад¹, А.С.Лучко²

¹Калининградский филиал Федерального исследовательского центра
«Информатика и управление» Российской академии наук, *ser-list-post@yandex.ru*

²ООО «Автотор информационные технологии», *luchko@inbox.ru*

При построении систем распределенного искусственного интеллекта для решения практических проблем обычно требуется объединять в составе системы и согласовывать работу агентов, созданных различными командами разработчиков, имеющих несовместимые цели и модели предметной области. В этой связи для учета субъективности и динамического характера проблем актуальна разработка в рамках многоагентного подхода [1 – 4] нового класса интеллектуальных систем – рефлексивно-активных систем искусственных гетерогенных интеллектуальных агентов (РАСИГИА), на основе модели гибридных интеллектуальных многоагентных систем [5]. Агенты РАСИГИА взаимно моделируют рефлексивные позиции друг друга, динамически вырабатывают тактики и стратегии своего поведения, релевантные моделям своих контрагентов, по мере необходимости в процессе решения проблем привлекают новых агентов из пула доступных агентов, построенных различными разработчиками, и исключают из своего состава существующих агентов, «на лету» перестраивая состав агентов и структуру связей между ними. Это позволяет РАСИГИА в ходе самоорганизации адаптироваться к особенностям проблем, которые перед ней возникают, в частности, учитывать их комплексное строение, сетевой характер условий и целей, непрозрачность, субъективность и динамичность. Один из механизмов, который обеспечивает самоорганизацию агентов в сильном смысле [6], т.е. возникающую в результате распределенного взаимодействия агентов без явного централизованного управления, – децентрализованная выработка согласованного представления об

⁶ Исследование выполнено за счет гранта Российского научного фонда № 23-21-00218, <https://rscf.ru/project/23-21-00218/>

объекте управления, цели коллективной работы и нормах взаимодействия путем переговоров. Это позволяет преодолевать разногласия и избегать конфликтов, вызванных различиями агентов, учитывать в своих рассуждениях позиции друг друга, снижая длительность согласования коллективных решений.

Переговоры агентов РАСИГИА определим, используя формулировку из [7], как процесс взаимодействия между ними для достижения собственных целей в отношении предмета рассмотрения, в рамках которого каждый из них имеет равные возможности в плане контроля ситуации, инициативы в ходе обсуждения и принятия решений. Стратегия переговоров – заранее определенный подход или общий план действий агента для достижения собственной цели в результате переговоров [8]. В рамках бихевиористского подхода к исследованию переговоров Д. Пруитт предлагает две модели выбора стратегии в ходе переговоров: «двойной заботы» и «реализуемости» [9]. Модель «двойной заботы» описывает правила выбора переговорной стратегии одним из участников переговоров на основе соотношения значимости собственной выгоды и заботы о поддержании и развитии позитивных отношений с другим участником переговоров, которая выражается в учете его интересов и обеспечении выгоды для него. Согласно модели «двойной заботы» выделяются следующие основные стратегии и правила их выбора [10–12]:

- избегание активного проведения переговоров или, в целом, уклонение от участия в них. Данная стратегия выбирается стороной переговоров, если она мало заинтересована в получении выгоды в результате переговоров как для себя, так и для другой стороны, например, когда она удовлетворена своим положением и ей безразлично или она не желает, чтобы другая сторона улучшила свои позиции в результате переговоров;

- приспособление, когда участник переговоров готов пренебречь своими интересами и даже намеренно «проиграть» ради сохранения хороших отношений с противоположной стороной. Такая стратегия актуальна, если для такого субъекта отношения с противоположной стороной ставятся выше собственной выгоды;

– конкуренция, при которой сторона переговоров стремится максимизировать свой выигрыш, независимо от того как это повлияет на другую сторону переговоров и отношения между ними;

– сотрудничество («решение проблем»), предполагающая стремление стороны переговоров к обеспечению выигрыша обоих участников, с целью максимизации собственной выгоды при сохранении или улучшении отношений с другой стороной. При этом данную стратегию сложнее всего реализовать, так как для этого требуется выявление основной проблемы в ходе серьезного анализа и оглашения истинных интересов сторон, поиск нетривиальных решений в ходе мозгового штурма;

– компромисс – простая, справедливая и быстро реализуемая стратегия, заключающаяся в умеренном преследовании как собственных интересов, так и учете интересов противоположной стороны. Данная стратегия – комбинированный подход, применяющийся участником, когда на него оказывается давление или необходимо быстро принять решение.

Экспериментальные исследования продемонстрировали, что стратегия сотрудничества, выбранная всеми участниками переговоров, наиболее выгодна с точки зрения максимизации коллективного результата их работы, т.е. с точки зрения коллектива предпочтительно, чтобы каждый участник заботился как о собственной выгоде, так и о выгоде других участников переговоров [9]. Слабая обеспокоенность о получении собственной выгоды приводит к уступчивости участников переговоров и низким результатам совместной работы.

На выбор стратегии переговоров влияет также ее «реализуемость», т.е. возможность решения поставленной проблемы с ее помощью в ходе переговоров. Таким образом, даже если стратегия релевантна модели «двойного выбора», в случае ее нереализуемости она не будет выбрана участником для использования в ходе переговоров. Реализуемость стратегии сотрудничества определяется числом предполагаемых точек соприкосновения сторон, определяющем вероятность нахождения взаимоприемлемого решения сторонами. Д. Пруитт выделяет следующие факторы повышающих реализуемость стратегии сотрудничества:

- уверенность в собственных навыках решения проблем;
- опыт совместного успешного решения проблем в рамках предыдущего сотрудничества;
- наличие посредника, облегчающего решение проблем и коммуникативную деятельность;
- наличие доверия со стороны хотя бы одного из участников переговоров при условии, что доверенная сторона отстаивает свои позиции и выгоду, в противном случае другая сторона выберет стратегию конкуренции, ожидая, что доверенная сторона уступит.

Стратегия конкуренции предпочтительней для участника переговоров, если другая сторона мало заботится о собственной выгоде и легко идет на уступки. Согласно Д. Пруитту конкуренция – самоограничивающаяся стратегия, так как успех одной из сторон приближает другую к позиции, не допускающей дальнейших уступок, что затрудняет развитие успеха и увеличивает цену победы в виде возможной эскалации конфликта или порицания со стороны третьих сторон [9].

Стратегия избегания может быть предпочтительной для участника переговоров, который менее восприимчив к нехватке времени по сравнению с другой стороной, если обе стороны готовы легко идти на уступки, так как бездействие усиливает ситуацию цейтнота, а уступка – наиболее распространенная реакция в такой ситуации.

Для формирования переговорной стратегии рефлексивного агента предлагается метод на основе нечеткого вывода Мамдани, реализующий модель «двойной заботы» Д. Пруитта [12]. Метод использует три входных лингвистических переменных: «жажда собственной выгоды», «забота о выгоде других агентов» и «длительность использования стратегии». В качестве выходной используется лингвистическая переменная «стратегия». Результат работы метода представляется в виде текстовой переменной «переговорная стратегия» *ngstr*. Кроме того, метод предполагает настройку параметра «число итераций» *nit* лингвистической переменной «длительность использования стратегии», что обеспечивает различную восприимчивость агентов к ситуации нехватки времени.

Лингвистическая переменная «жажда собственной выгоды» описывается выражением

$$sidl = \langle \beta_{sidl}, T_{sidl}, U_{sidl}, G_{sidl}, M_{sidl} \rangle,$$

где β_{sidl} = «жажда собственной выгоды» – наименование лингвистической переменной; $T_{sidl} = \{\text{«низкая»}; \text{«высокая»}\}$ – терм-множество ее значений, названий нечеткой переменной; $U_{sidl} = [0; 1]$ – универсум нечетких переменных; $G_{sidl} = \emptyset$ – процедура образования из элементов множества T_{sidl} новых термов; $M_{sidl} = \{\mu_{низкая}, \mu_{высокая}\}$ – процедура, ставящая в соответствие каждому терму множества T_{sidl} осмысленное содержание путем формирования нечеткого множества. При формировании нечетких множеств используются сигмоидальные функции

$$sigmf(u, b, c) = (1 + e^{-b(u-c)})^{-1},$$

где u – элемент нечеткого множества; b, c – параметры функции принадлежности. Первоначально заданы следующие параметры функций принадлежности: $\mu_{низкая} = sigmf(u_{sidl}; -10; 0, 5)$, $\mu_{высокая} = sigmf(u_{sidl}; 10; 0, 5)$. Параметры этих и других функций принадлежности, рассмотренных в работе, должны быть уточнены в ходе тестирования системы.

Лингвистическая переменная «забота о выгоде других агентов» задается аналогично

$$oidl = \langle \beta_{oidl}, T_{oidl}, U_{oidl}, G_{oidl}, M_{oidl} \rangle,$$

где β_{oidl} = «забота о выгоде других агентов»; $T_{oidl} = \{\text{«низкая»}; \text{«высокая»}\}$; $U_{oidl} = [0; 1]$; $G_{oidl} = \emptyset$; $M_{oidl} = \{\mu_{низкая}, \mu_{высокая}\}$, $\mu_{низкая} = sigmf(u_{oidl}; -10; 0, 5)$, $\mu_{высокая} = sigmf(u_{oidl}; 10; 0, 5)$.

Лингвистическая переменная «длительность использования стратегии», отражающая число итераций в ходе переговоров в течение которых используется текущая стратегия, представляется выражением

$$stdl = \langle \beta_{stdl}, T_{stdl}, U_{stdl}, G_{stdl}, M_{stdl} \rangle,$$

где $\beta_{stdl} = \langle \text{«длительность использования стратегии»} \rangle$; $T_{stdl} = \{ \langle \text{«малая»} \rangle; \langle \text{«большая»} \rangle \}$; $U_{stdl} = \mathbb{N}_0$; $G_{stdl} = \emptyset$; $M_{stdl} = \{ \mu_{\text{малая}}, \mu_{\text{большая}} \}$; $\mu_{\text{малая}} = \text{sigmf}(u_{durpl}; -0, 2; nit)$, $\mu_{\text{большая}} = \text{sigmf}(u_{durpl}; 0, 5; nit)$.

Лингвистическая переменная «стратегия» описывается выражением

$$strl = \langle \beta_{strl}, T_{strl}, U_{strl}, G_{strl}, M_{strl} \rangle,$$

где $\beta_{strl} = \langle \text{«стратегия»} \rangle$; $T_{strl} = \{ \langle \text{«избегание»} \rangle, \langle \text{«приспособление»} \rangle, \langle \text{«конкуренция»} \rangle, \langle \text{«компромисс»} \rangle, \langle \text{«сотрудничество»} \rangle \}$; $U_{strl} = [0; 1]$; $G_{strl} = \emptyset$; $M_{strl} = \{ \mu_{\text{избегание}}, \mu_{\text{приспособление}}, \mu_{\text{конкуренция}}, \mu_{\text{компромисс}}, \mu_{\text{сотрудничество}} \}$. Эти нечеткие множества задаются с помощью колоколообразных функций

$$bmf(u, a, b, c) = (1 + |u - c|^{2b} |a|^{-2b})^{-1},$$

где u – элемент нечеткого множества; a, b, c – параметры функции принадлежности. Первоначально заданы следующие параметры функций принадлежности нечетких множеств: $\mu_{\text{избегание}} = bmf(u_{strl}; 0, 25; 4; 0)$, $\mu_{\text{приспособление}} = bmf(u_{strl}; 0, 125; 2; 0, 3)$, $\mu_{\text{конкуренция}} = bmf(u_{strl}; 0, 125; 2; 0, 5)$, $\mu_{\text{компромисс}} = bmf(u_{strl}; 0, 125; 2; 0, 7)$, $\mu_{\text{сотрудничество}} = bmf(u_{strl}; 0, 25; 4; 1)$.

Переговорная стратегия определяется с использованием перечисленных выше лингвистических переменных в результате нечеткого вывода Мамдани по следующим правилам:

1. ЕСЛИ $sidl$ ЕСТЬ «низкая» И $oidl$ ЕСТЬ «низкая», ТО $strl$ ЕСТЬ «избегание».
2. ЕСЛИ $sidl$ ЕСТЬ «низкая» И $oidl$ ЕСТЬ «высокая», ТО $strl$ ЕСТЬ «приспособление».
3. ЕСЛИ $sidl$ ЕСТЬ «высокая» И $oidl$ ЕСТЬ «низкая» И $stdl$ ЕСТЬ «малая», ТО $strl$ ЕСТЬ «конкуренция».
4. ЕСЛИ $sidl$ ЕСТЬ «высокая» И $oidl$ ЕСТЬ «высокая» И $stdl$ ЕСТЬ «малая», ТО $strl$ ЕСТЬ «сотрудничество».
5. ЕСЛИ $sidl$ ЕСТЬ «высокая» И $oidl$ ЕСТЬ «низкая» И $stdl$ ЕСТЬ «большая», ТО $strl$ ЕСТЬ «компромисс».

6. ЕСЛИ $sidl$ ЕСТЬ «высокая» И $oidl$ ЕСТЬ «высокая» И $stdl$ ЕСТЬ «большая», ТО $strl$ ЕСТЬ «компромисс».

В результате текстовая переменная «переговорная стратегия» $ngstr$ может быть определена в соответствии со значением лингвистической переменной $strl$ следующим образом:

$$ngstr = \underset{t \in \Gamma_{strl}}{\operatorname{argmax}}(\mu_t(u_{strl})).$$

Таким образом, рассмотрены основные стратегии ведения переговоров реальными специалистами и основания для их выбора с точки зрения двух моделей: «двойной заботы» и «реализуемости». Отмечается, что выбор всех участников переговоров в пользу стратегии сотрудничества обеспечивает максимизацию коллективного результата их работы. Предложен метод выработки рефлексивными агентами стратегии поведения при переговорах, обеспечивающий выбор и смену переговорных стратегий в зависимости от таких характеристик агента как «жажда собственной выгоды», «забота о выгоде других агентов», а также длительностью использования выбранной стратегии. Данный метод позволяет агенту выбирать одну из пяти переговорных стратегий согласно настройкам, сделанным разработчиками агента или пользователем РАСИГИА в соответствии с моделью «двойной заботы» Д. Пруитта [12]. При этом если выбранная стратегия долго не приносит требуемого результата, агент переходит к реализации компромиссной стратегии, обеспечивая принятие взаимоприемлемого решения за разумное время.

Список литературы

1. Хорошевский В.Ф. Поведение интеллектуальных агентов: модели и методы реализации / В.Ф. Хорошевский // 4-й Международный семинар по прикладной семиотике, семиотическому и интеллектуальному управлению: Сб. научных трудов. — Переславль-Залесский: РАИИ, 1999. — С. 5 – 20.
2. Тарасов В.Б. От многоагентных систем к интеллектуальным организациям: философия, психология, информатика / В.Б. Тарасов. – М.: Эдиториал УРСС, 2002.

3. Городецкий В.И. Инструментальные средства для открытых сетей агентов / В.И. Городецкий, О.В. Карсаев, В.В. Самойлов и др. // Известия РАН. Теория и системы управления. — 2008. — №3. — С. 106 – 124.
4. Wooldridge M. An Introduction to Multiagent Systems / M. Wooldridge. — New York, NY: Wiley, 2009.
5. Колесников А.В. Гибридные интеллектуальные системы с самоорганизацией: координация, согласованность, спор / А.В. Колесников, И.А. Кириков, С.В. Листопад. — М.: ИПИ РАН, 2014. — 189 с.
6. Serugendo G.D.M. Self-organization in multiagent systems / G.D.M. Serugendo, M.-P. Gleizes, A. Karageorgos // The Knowledge engineering review. — 2005. — Vol. 20. — № 2. — pp. 165 – 189.
7. Рыбкин А.Г. Стратегия сложных переговоров: учеб. Пособие / А.Г. Рыбкин, О.К. Эмих. — М.: ИНФРА-М, 2019. — 260 с.
8. Negotiation Strategy. E-print: <https://www.negotiations.com/definition/negotiation-strategy/>.
9. Pruitt D. Strategic Choice in Negotiation / D. Pruitt // Negotiation Theory and Practice. — Cambridge: The Program on Negotiation at Harvard Law School, 1991. — pp. 27 – 46.
10. Lewicki R.J. Mastering Business Negotiation: A Working Guide to Making Deals and Resolving Conflict / R.J. Lewicki, A. Hiam. — San Francisco: Jossey-Bass. A Wiley Imprint, 2006.
11. Стрёмовская А.Л. Возможные стратегии ведения переговорного процесса // Российский внешнеэкономический вестник, 2012. №8. С. 79-88
12. Carnevale P., Pruitt D. Negotiation and Mediation // Annual Review of Psychology, 2003. Vol. 43. pp. 531-582.

АНАЛИЗ ЭЛЕКТРОЭНЦЕФАЛОГРАММ ПАЦИЕНТОВ С ЭПИЛЕПСИЕЙ НА ОСНОВЕ ВЕЙВЛЕТ-ПРЕОБРАЗОВАНИЙ

А.В. Медиевский¹, С.В. Кириллова², А.Г. Зотин³, К.В. Симонов⁴,

А.С. Кургляков⁴

¹Красноярский государственный медицинский университет имени профессора
В.Ф. Войно-Ясенецкого, *amedievsky@yandex.ru*

²Сибирский федеральный университет, *svkirillova2009@yandex.ru*

³Сибирский государственный университет науки и технологий имени академика
М.Ф. Решетнева, *zotin@sibsau.ru*

⁴Институт вычислительного моделирования СО РАН, *simonovkv@icm.krasn.ru*

Введение. Исследование посвящено изучению вейвлетных характеристик сигналов ЭЭГ (электроэнцефалограмма), которые позволяют выявлять характерные закономерности в паттернах физиологических ритмов здорового человека и определять изменения в динамической сложности паттернов при возникновении различных патологических состояний. В работе показана возможность применения вейвлетных характеристик паттернов ЭЭГ для автоматического выявления эпилептиформных разрядов. Предложен метод определения частот ЭЭГ, относящихся к шумовым. Показаны возможности сжатия и фильтрации сигналов ЭЭГ. В итоге, разработана вычислительная методика анализа сигналов ЭЭГ применительно к эпилепсии. Для диагностики многих заболеваний в неврологии, в частности, используется электроэнцефалография (ЭЭГ) – метод исследования головного мозга, основанный на регистрации его электрических потенциалов. Для выявления активностей на электроэнцефалограмме применяются различные методы, включая вейвлет-преобразование одномерных сигналов [1-4].

Исследование направлено на разработку вычислительного инструментария для решения диагностических задач. Изучение механизмов изменения сложности паттернов физиологических сигналов представляет актуальную задачу современной нейрофизиологии и имеет фундаментальное значение, так как способствует развитию представлений об общих принципах вариабельности физио-

логических ритмов, связанных с состоянием здоровья и сложностью процессов управления функциональными нервными связями [3-4]. Вейвлет-преобразования имеют следующие преимущества: возможность оценить динамику изменения ЭЭГ в каждый момент времени, т.е. имеем распределение мощности спектральных составляющих по диапазону частот; возможность получить локальный спектр для отдельных «вспышек» сигнала ЭЭГ. Практическое применение: вейвлет-преобразование позволяет анализировать динамику ЭЭГ в каждый момент времени и подробно исследовать отдельные вспышки сигнала в форме отдельного графика. На сегодняшний день особенности вейвлет-преобразования сигналов ЭЭГ используют для решения различных задач в неврологии [5-7]. Дальнейший анализ разложенного сигнала позволяет в автоматическом режиме детектировать элементы ЭЭГ, свойственные для отдельных неврологических состояний, преимущественно для эпилепсии. Это обстоятельство значительно упрощает анализ записей, продолжительность которых может превышать 10 часов, а также снизит вероятность формирования ошибочного заключения. Для оценки эффективности лекарственного купирования эпилептических приступов необходима разработка алгоритмов, позволяющих по данным ЭЭГ предсказывать эпилептиформные разряды и отличать их от активности, вызванной двигательными артефактами.

Многоуровневый анализ сигналов ЭЭГ. В терминах обработки сигнала вейвлет-преобразование представляет последовательное разложение сигнала на две составляющие: низкочастотную и высокочастотную. Любой ортогональный вейвлет определяет пару фильтров разложения $\{h_k\}$ и $\{g_k\}$ – низкочастотный и высокочастотный соответственно, примером является используемый в работе вейвлет Добеши-4. На первом этапе к сигналу применяется низкочастотный $\{h_k\}$ фильтр, а затем высокочастотный $\{g_k\}$ фильтр. В результате действия $\{h_k\}$ получается сглаженная составляющая сигнала $cA_1 = \{a_j^1\}$, а в результате $\{g_k\}$ – детализирующая $cD_1 = \{d_j^1\}$, т.е. cD_1 – это «детали», которые были потеряны при сглаживании. Значения a_j^1 называют коэффициентами аппроксимации, а d_j^1 – коэф-

коэффициентами детализации первого уровня разложения. Затем процедура декомпозиции сигнала повторяется, но уже применительно к коэффициентам $\{a_j^1\}$. Формируются наборы коэффициентов $\{a_j^2\}$ и $\{d_j^2\}$ представляющие собой коэффициенты аппроксимации и детализации второго уровня разложения. Разложение применяется итеративно к низкочастотным (аппроксимирующим) коэффициентам. На каждом последующем уровне находят аппроксимирующие и детализирующие коэффициенты. Повторяя процедуру декомпозиции m раз, получаем вместо исходного сигнала наборы коэффициентов $cA_m, cD_m, cD_{m-1}, \dots, cD_1$. Результатом вейвлет-преобразования является многоуровневое иерархическое представление сигнала. Каждый уровень разложения можно исследовать и обрабатывать отдельно. Схема декомпозиции сигнала изображена на рисунке 1. Восстановление сигнала происходит в обратном порядке.




Рис. 1. Схематическое представление вейвлет-разложения сигнала

Для вейвлет-анализа использованы сигналы ЭЭГ из базы, размещенной на сайте <https://physionet.org/content/chbmit/1.0.0/>. В частности использована запись chb01_01.edf (Channel 1: FP1-F7). Исходный файл конвертирован в chb01_01.dat. Частота дискретизации сигнала – 256 отсчетов в секунду. Продолжительность записи составляет 1 час, но для обработки выбраны первые 10 секунд. Для вейвлет-разложения применялся вейвлет Добеши db4. Из имеющегося временного ряда ЭЭГ выбран фрагмент длиной 2560 отсчетов (рис. 2).

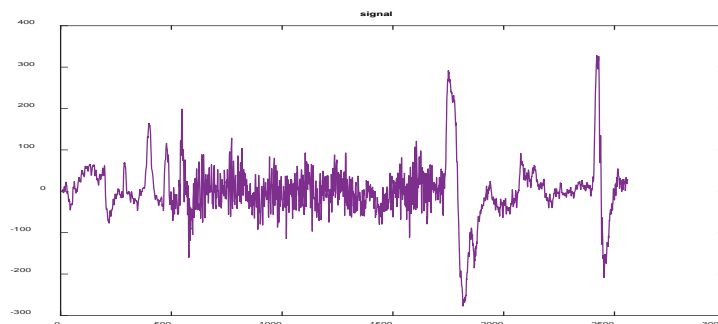


Рис. 2. График ЭЭГ

Вейвлет $\psi(t)$ Добеши db4 имеет носитель на промежутке $[0,7]$ и центральную частоту $Fr = 0.7143$ Гц. Поскольку $\Delta t = 1/256$, то носитель вейвлета $\tilde{\psi}(t) = \psi(t / \Delta t)$ находится на промежутке $[0, 7 \Delta t]$ и центральная частота вейвлета $\tilde{\psi}(t)$, используемого для первого уровня разложения, равна $Fr1 = 0.7143 \times 256 = 182.86$ Гц. Для второго уровня разложения частота вейвлета будет в два раза меньше, $Fr2 = 91.43$ Гц; а для третьего уровня – в два раза меньше, чем для второго уровня, $Fr3 = 45.72$ Гц. Вейвлет-коэффициенты $cD1, cD2, cD3$ отражают характеристики ЭЭГ на указанных частотах. Отнесение данных компонент к указанным частотам достаточно условно и не соответствует аналогичному понятию для разложения Фурье. Для нахождения компонент сигнала сделаем прямое восстановление отдельно по каждому набору детализирующих коэффициентов. Получаем компоненты сигнала $ScD1, ScD2, ScD3$. Для количественного анализа результатов можно использовать статистические характеристики (а именно, среднее квадратическое отклонение) и энергетический спектр вейвлет-коэффициентов $cD1, cD2, cD3$ и компонент сигнала $ScD1, ScD2, ScD3$.

Таким образом, многоуровневый анализ сигнала ЭЭГ позволяет производить исследование отдельных составляющих сигнала с целью выявления диагностических особенностей. При этом от выбора вейвлета зависит, какие частотные составляющие будут выделены в результате разложения. Так вейвлет с бóльшей центральной частотой способен выделить компоненту более высокой частоты, чем вейвлет с меньшей центральной частотой. Наличие диагностически значимых количественных параметров при анализе электроэнцефалограмм пациентов с симптоматической эпилепсией показывает возможность

использование их для автоматической классификации периодов до, во время и после эпилептического приступа.

Непрерывный вейвлет-анализ сигналов ЭЭГ. Для непрерывного вейвлет-анализ использована та же запись ЭЭГ и тот же ее фрагмент, что и в предыдущем пункте. Выполнено непрерывное вейвлет-разложение указанного фрагмента ЭЭГ. Если нас интересует не только высокочастотные составляющие, но и нижние частоты, то масштабный коэффициент нужно взять достаточно большим. Пределы изменения масштабного коэффициента зависят от выбора вейвлета и от того, какие частоты хотим отразить в результате разложения. Например, центральная частота вейвлета Добеши db4 равна 0.7143 Гц. Поскольку в нашем случае $\Delta t = 1/256$, то центральная частота вейвлета Добеши db4, используемого для первого уровня разложения (когда масштабный коэффициент $a = 1$), равна $Fr = 0.7143 \times 256 = 182.86$ Гц. Для значения $a = 200$ имеем частоту $182.86/200 = 9.143$ Гц. Следовательно, если a изменяется в пределах от 1 до 200, то в вейвлет-коэффициентах будут отображены свойства ЭЭГ в пределах частот от 182.86 Гц до 9.143 Гц. Для того чтобы отразить более высокие частоты, необходимо выбрать значения масштабного коэффициента a , меньшие единицы, либо выбрать другой вейвлет с большей центральной частотой. Укажем центральные частоты некоторых часто используемых вейвлетов: $Fr(db2) = 0.667$ Гц, $Fr(db4) = 0.7143$ Гц, $Fr(morl) = 0.8125$ Гц, $Fr(haar) = 0.9961$ Гц.

В среде MATLAB связь масштабирующего параметра a с частотой выражается формулой: $a = \frac{f_c}{\Delta t \cdot f}$, где f_c – центральная частота вейвлета, вызываемая функцией `centfrq()`; Δt – время дискретизации исследуемого сигнала; f – анализируемая частота. Для выбранного фрагмента ЭЭГ выполнено непрерывное вейвлет-преобразование с использованием вейвлета Добеши db4, при этом выбрано значение масштаба a в пределах от 1 до 600 с шагом 4. В итоге, были отображены частоты от 182.86 Гц до 0.31 Гц. Визуализация вейвлет-преобразования позволяет исследовать структуру изучаемого сигнала по динамике частот исходного ряда во времени и, следовательно, разграничивать периоды, соответствующие различным неврологическим состояниям. Заметим,

что при равномерном изменении масштабного коэффициента a , увидеть на визуализации высокочастотную компоненту сигнала ЭЭГ весьма затруднительно, в то же время низкие частоты будут отображены хорошо. Эту неравномерность можно исправить применением логарифмической шкалы. Вместо значений $a = k$ ($k = 1, \dots, N$) по оси ординат берутся $a = r^k$ ($k = 0, \dots, N$). Вейвлет-преобразование сигнала ЭЭГ с применением логарифмического масштаба реализовано в MATLAB. Оценим, до каких значений a высокочастотные компоненты ЭЭГ на спектрограмме фактически не будут видны. Отсутствие на визуализации высокочастотной составляющей говорит о ее шумовой природе. Следовательно, можно оценить верхнюю границу частот сигнала, относящихся к шумовым. На спектрограмме, полученной с применением вейвлета db4, только со значения $a = 2$ (соответственно, $F_d = 182.86/2 = 91.43$ Гц) можно наблюдать проявление высокочастотной составляющей. А на спектрограмме, полученной с помощью вейвлета gaus3, можно заметить высокочастотную составляющую со значения $a = 1.17$ ($F_g = 102.4 / 1.17 = 87.52$ Гц).

В качестве оценки верхней границы частот сигнала, относящихся к шумовым выберем $F = \max\{F_d, F_g\} = 91.43$ Гц. Это не позволит при дальнейшем разложении убрать значимые компоненты сигнала. Алгоритм оценки верхней границы частот сигнала, относящихся к шумовым, состоит в следующем: выбор вейвлета (или набора вейвлетов); реализация непрерывного вейвлет-преобразования и его визуализация в логарифмическом масштабе (для каждого вейвлета из набора); выявление масштабного коэффициента a до которого на спектрограмме высокочастотные составляющие сигнала фактически не видны и вычисление соответствующей частоты (для каждого вейвлета из набора); выбор максимальной частоты из предыдущего шага в качестве оценки верхней границы частот ЭЭГ, относящихся к шумовым (при использовании набора вейвлетов).

Для дальнейшего развития в этом алгоритме будет сделано автоматическое определение верхней границы частот сигнала, например, модифицировав шаг «выявление масштабного коэффициента a », но не используя видимость на спектрограмме, а применяя оценку значения (интенсивности сигнала) в спектрограмме. В итоге, показаны возможности применения

непрерывного вейвлет преобразования для анализа сигналов ЭЭГ. Приведены различные способы визуализации спектрограммы, способствующие выявлению диагностические особенностей сигнала. Предложен метод определения верхней границы частот ЭЭГ, относящихся к шумовым, основанный на интерпретации спектрограммы, представленной логарифмическом масштабе.

Удаление шума, сжатие и сглаживание сигналов ЭЭГ. Одна из областей применения вейвлет-преобразования это задача сжатия сигналов и изображений. Вейвлетное сжатие обеспечивает высокую эффективность, т.к. позволяет устранять высокочастотную составляющую сигнала, которая представляет собой либо шум, либо информацию о мелких деталях, как правило, не являющихся важными для исследователя. Побочным эффектом такого сжатия является сглаживание сигнала.

Идея вейвлетного сжатия заключается в том, что хранится не сам сигнал, а полученный в результате вейвлет-преобразования набор аппроксимирующих и детализирующих коэффициентов, при этом близкие по абсолютной величине к нулю детализирующие коэффициенты обнуляются с применением пороговое значение. Другой вариант – полностью обнулять коэффициенты детализации нескольких первых уровней разложения, таким образом, устраняя высокочастотные компоненты. Задача сжатия сигнала ЭЭГ является актуальной, поскольку при использовании электроэнцефалографа с высоким разрешением полученные сигналы могут иметь достаточно большие объемы. При этом сжатие сигнала можно провести только за счет удаления шума, полученный сигнал не потеряет диагностически значимые признаки.

В предыдущем пункте показано, что верхняя граничная частота сигнала ЭЭГ, заметно влияющая на его форму, не превышает $F = 91.43$ Гц. Поэтому составляющие сигнала с частотами выше 91.43 Гц можно удалить без потери диагностической информации. В итоге, получаем один из вариантов сжатия и сглаживания. Для этой задачи используем вейвлет Добеши db4. Для наших расчетов центральная частота вейвлета db4, используемого для второго уровня разложения равна $Fr_2 = 91.43$ Гц. Поэтому для удаления шума можно сделать разложение до второго уровня включительно и для восстановления взять нулевыми все полученные детализирующие коэффициенты cD_1 , cD_2 . В этом

случае получаем сжатие сигнала в $2^2 = 4$ раза. Заметим, что в данном расчете F_{r2} равно F – оценке верхней границы частот сигнала, относящихся к шумовым, найденной в предыдущем пункте. В случае неравенства можно попробовать подобрать вейвлет с такой центральной частотой, чтобы частота для N -го уровня разложения приблизительно была равна F .

Модифицированный алгоритм сжатия и сглаживания сигналов ЭЭГ состоит в следующем: оценка верхней границы частот ЭЭГ, относящихся к шумовым – F (этот шаг можно сделать автоматическим); подбор вейвлета, для которого справедливо следующее: частота для N -го уровня разложения приблизительно равна F ; разложение сигнала до уровня N и обнуление всех полученных детализирующих коэффициентов; хранение только аппроксимирующих коэффициентов (в результате происходит сжатие сигнала в 2^N раза); восстановление сигнала по полученным вейвлет-коэффициентам (в результате происходит сглаживание сигнала).

Методика вейвлет-анализа сигнала ЭЭГ, применительно к эпилепсии. Методика включает следующие этапы:

1. Подготовка данных. Операции, предшествующие анализу сигнала ЭЭГ: экспертный выбор диапазонов сигнала для анализа и преобразование данных в формат для дальнейшего вейвлет-анализа сигнала ЭЭГ.

2. Выбор вейвлета. Выбора материнского вейвлета для наилучшего проявления диагностических особенностей сигнала ЭЭГ.

3. Многоуровневый вейвлет-анализ сигнала ЭЭГ. Выполняются иерархическое вейвлет-разложение сигнала ЭЭГ по уровням декомпозиции и анализ составляющих сигнала, а также визуальный, статистический и энергетический анализы вейвлет-коэффициентов и компонентов сигнала ЭЭГ для выделения диагностически значимых признаков. Наличие таких параметров при анализе ЭЭГ пациентов с симптоматической эпилепсией показывает возможность использование их для автоматической классификации периодов до, во время и после эпилептического приступа.

4. Визуализация непрерывного вейвлет преобразования сигнала ЭЭГ. Выполняется непрерывное вейвлет-преобразование сигнала ЭЭГ и его дальнейшая визуализация. Различные способы визуализации спектрограммы

способствуют выявлению диагностических особенностей в сигнале ЭЭГ.

5. *Выявление верхней границы частот сигнала ЭЭГ, относящихся к шумовым.* Процедура основана на интерпретации спектрограммы, представленной в логарифмическом масштабе. Частотные составляющие можно считать шумовыми, если на спектрограмме они фактически не присутствуют.

6. *Сжатие и фильтрация сигнала ЭЭГ при помощи удаления шумовой компоненты.* Выполняется удаление шумовой компоненты оценка, которой произведена на предыдущем этапе. В результате происходит сжатие и фильтрация сигнала ЭЭГ. Анализ отфильтрованного сигнала ЭЭГ дает новую диагностически значимую информацию, а сжатие сигнала является важным этапом в случае необходимости хранения больших объемов данных.

7. *Сжатие и фильтрация сигнала ЭЭГ при помощи нахождения пороговых значений.* Выполняется как альтернатива или дополнение предыдущего этапа и включает в себя фильтрацию и сжатие сигнала ЭЭГ встроенными функциями (например, MATLAB). Заметим, что анализ сигнала ЭЭГ не обязан происходить линейно. Возможен возврат к предыдущим этапам, если не достигнута цель исследования. Например, в настоящей работе для анализа сигнала ЭЭГ выбран вейвлет Добеши-4, а этап выявления шумовой компоненты сигнала ЭЭГ дополнен использованием гауссова вейвлета.

Заключение. Предложена усовершенствованная вычислительная методика вейвлет-анализа и визуализации сигналов ЭЭГ, применительно к решению диагностических задач при эпилепсии. Предложен модифицированный алгоритм эффективного сжатия сигналов ЭЭГ посредством удаления шумовой компонент. Основой этого алгоритма является метод определения верхней границы частот ЭЭГ, которые можно отнести к шумовым. Исследована структура изучаемого сигнала по динамике частот исходного ряда по времени: шумовая составляющая, колебательная составляющая и выделенный сигнал (высокоэнергетический), обусловленный проявлением эпилепсии. Показано, что в период, предшествующий эпилептическому разряду, энергия сигнала значительно возрастает.

Список литературы

1. Алиев Р.Р. Современные математические методы анализа мозговой активности / Р.Р.Алиев // В сб.: Новые информационные технологии в медицине, биологии, фармакологии и экологии: материалы Международной конференции / под ред. Е.Л. Глориозова, 2015. — С. 367 – 371.
2. Туровский Я.А. Вейвлет-анализ электроэнцефалограммы: электрофизиологические феномены и их интерпретация / Я.А.Туровский // Вестник Волгоградского государственного медицинского университета. — 2011. — № 3 (39). — С. 97 – 99.
3. Габова А.В. Метод вейвлет-преобразования в неврологии: анализ частотно-временных характеристик типичных и атипичных разрядов неконвульсивной эпилепсии / А.В.Габова, Г.Д.Кузнецова, В.В.Гнездицкий, А.С.Базян, Ю.В.Обухов // Анналы клинической и экспериментальной неврологии. — 2009. — Т. 3. — № 4. — С. 39 – 44.
4. Дик О.Е. Механизмы изменения динамической сложности паттернов физиологических сигналов / О.Е.Дик. Автореферат дисс. на соискание ученой степени доктора биологических наук (03.03.01 – физиология). Санкт-Петербург, 2018. — 42 с.
5. Добеши И. Десять лекций по вейвлетам / И.Добеши. — Ижевск: НИЦ Регулярная и стохастическая динамика, 2001. — 115 с.
6. Грубов В.В. Вейвлетный анализ сонных веретен на ЭЭГ и разработка метода их автоматической диагностики / В.В.Грубов, А.А.Овчинников, Е.Ю.Ситникова, А.А.Короновский, А.Е.Храмов // Известия высших учебных заведений. Прикладная нелинейная динамика. — 2011. — Т. 19. — № 4. — С. 91 – 108.
7. Габова А.В. Использование вейвлет-преобразований для анализа электрической активности мозга при болезни Паркинсона / А.В.Габова, В.В.Гнездицкий, А.В.Карабанов, С.Н.Иллариошкин, Ю.В.Обухов, А.А.Морозов, М.С.Королев, Т.П.Шевцова., Г.Д.Кузнецова, А.С.Базян // Журнал: Нервные болезни. — 2012. — № 3. — С. 2 – 7.

СРАВНИТЕЛЬНЫЙ АНАЛИЗ КЛАСТЕРИЗАЦИИ ГЕНОВ 5S И 16S РНК ПО ТРИПЛЕТНОМУ СОСТАВУ

Ю.И.Овчинникова¹, М.Г.Садовский¹⁻⁴

¹Сибирский федеральный университет, ИФБиТ, *july.1406@mail.ru*

²Институт вычислительного моделирования СО РАН, *msad@icm.krasn.ru*

³Федеральный Сибирский научно-клинический центр ФМБА России,

⁴Красноярский государственный медицинский университет МЗ РФ

Связь между структурой нуклеотидных последовательностей, кодируемой ими функцией и таксономией носителя является важнейшим предметом исследования молекулярных биологов и биоинформатиков, а также специалистов по обработке больших массивов данных. В этом направлении существуют различные подходы; один из них связан с изучением связи структуры биологических макромолекул (конкретно – молекул рибосомальных РНК бактерий) и таксономии их носителей. Для указанных организмов классическим предметом исследования являются последовательности 16S РНК. Однако не меньший интерес представляет и изучение связи между структурой и таксономией для других последовательностей. В рамках настоящей работы изучена связь между структурой и таксономией на примере последовательностей 5S РНК бактерий.

При изучении связи структуры и таксономии очень важным является выбор генетических объектов, на которых исследуется данная связь. Традиционно таким объектом считаются последовательности 16S РНК, однако возможны и другие варианты, например, последовательности 5S РНК.

Настоящая работа имеет следующую цель: выявить подобию и различия кластеризации бактерий по триплетному составу генов 5S и 16S РНК. Заметим, что 5S РНК бактерий не являются самым широко распространённым объектом для такого рода исследований и сравнение полученных результатов с другими, например, построенными по кластеризации на основе генов 16S РНК бактерий, определяет новизну данной работы.

Для достижения указанной цели поставлены следующие задачи:

- 1) создание проиндексированной базы генов 5S и 16S РНК и их частотных словарей;
- 2) кластеризация генов 5S и 16S РНК методом упругих карт;
- 3) проведение сравнительного анализа трёх вариантов кластеризации: по 16S РНК, по 5S РНК и совместное распределение;
- 4) определение таксономического состава выявляемых кластеров.

Структура биологических макромолекул может быть определена многими различными способами. В рамках настоящей работы под структурой мы будем понимать частотный словарь триплетов (иногда также называемый частотным профилем) W_j ; здесь индекс j перечисляет рассматриваемые последовательности. Под частотным словарём триплетов будем понимать список всех триплетов, встречающихся в изучаемой последовательности, с указанием частот этих триплетов. Построение частотного словаря преобразует нуклеотидную (символьную) последовательность в точки в 63-мерном метрическом пространстве, делая их математическими объектами, позволяющими для своего изучения применять весь арсенал соответствующих средств.

Ранее была изучена устойчивость наблюдаемой кластеризации к случайному отбору исключаемых сверхпредставленных таксонов [1 – 3]: было показано, что триплетный состав различных генетических систем очень хорошо коррелирует с таксономическим положением носителей соответствующих генов. Однако зачастую видовой состав баз генетических данных (в нашем случае — базы SILVA и RDP) весьма смещён: некоторые таксоны низкого уровня представлены непропорционально большим количеством записей, что приводит к искажению картины распределения частотных словарей в метрическом пространстве. Стандартным выходом из такой ситуации является индексация базы данных: удаление части записей, находящихся в сверхпредставленных группах.

Перейдём к описанию самой работы и результатов. Последовательности генов 16S РНК были взяты в открытой базе данных RDP, последовательности генов 5S РНК – в открытой базе данных SILVA. Были взяты готовые проиндексированные базы данных генов 5S и 16S РНК. Ранее была решена задача, ориен-

тированная на подготовку 6 проиндексированных баз данных, которые не отличались по кластеризации генов 5S РНК бактерий. Проиндексированная база данных по 16S РНК подготовлена и представлена в работах, сделанных ранее [3]. Используя подготовленные базы данных 5S и 16S РНК, составлена база данных, включающая отделы бактерий, совпадающие для генов 5S и 16S РНК (таблица 1).

Таблица 1

Число представителей бактерий по отделам генов 5S и 16S РНК

Отделы	16S	5S
<i>Actinobacteriota</i>	24	20
<i>Bacteroidota</i>	695	70
<i>Firmicutes</i>	1201	1890
<i>Verrucomicrobiota</i>	189	172

Все последовательности генов 5S и 16S были преобразованы в частотные словари триплетов. Всякий частотный словарь отображает геном в 64-мерное метрическое пространство; близость двух геномов задается естественным образом — например, как близость двух точек в той или иной метрике. В данной работе использовалась Евклидова метрика. Один из 64 триплетов исключался, поскольку сумма всех частот в словаре равна 1. Формально исключить можно любой триплет, однако в данной работе исключался тот, для которого дисперсия, наблюдаемая по анализируемой выборке геномов, является минимальной. Был исключён триплет *CAC*, так как в исследуемой выборке он имеет наименьшее стандартное отклонение по сравнению с другими триплетами. Кластеризация методом упругих карт была реализована на основе отделов бактерий в данной базе: *Actinobacteriota*, *Bacteroidota*, *Firmicutes*, *Verrucomicrobiota*.

Ключевая идея в исследовании заключается в анализе распределения точек (каждая точка – это ген) в 63-мерном метрическом пространстве частот триплетов. В пространстве частот триплетов определялись собственные векторы, и

на них, как на базисе, строилась плоскость. На основе использования программы *VidaExpert* [4 – 7] построена упругая карта, которая отображалась во внутренних координатах с указанием распределения точек (генов) по ней.

При изучении распределения генов 5S РНК было установлено, что гены устойчиво распределяются по кластерам и каждый кластер содержит гены таксономически близких (либо одного и того же) отделов.

На втором этапе изучено совместное распределение генов 5S и 16S РНК (рисунок 1). Было установлено, что на упругой карте гены 5S и 16S РНК у разных отделов в целом отделяются – формируются выраженные отдельные кластеры, содержащие в основном только указанные гены.

На рисунках 1 – 3 представлены распределения генов 5S и 16S РНК в частотном пространстве по локальной плотности.

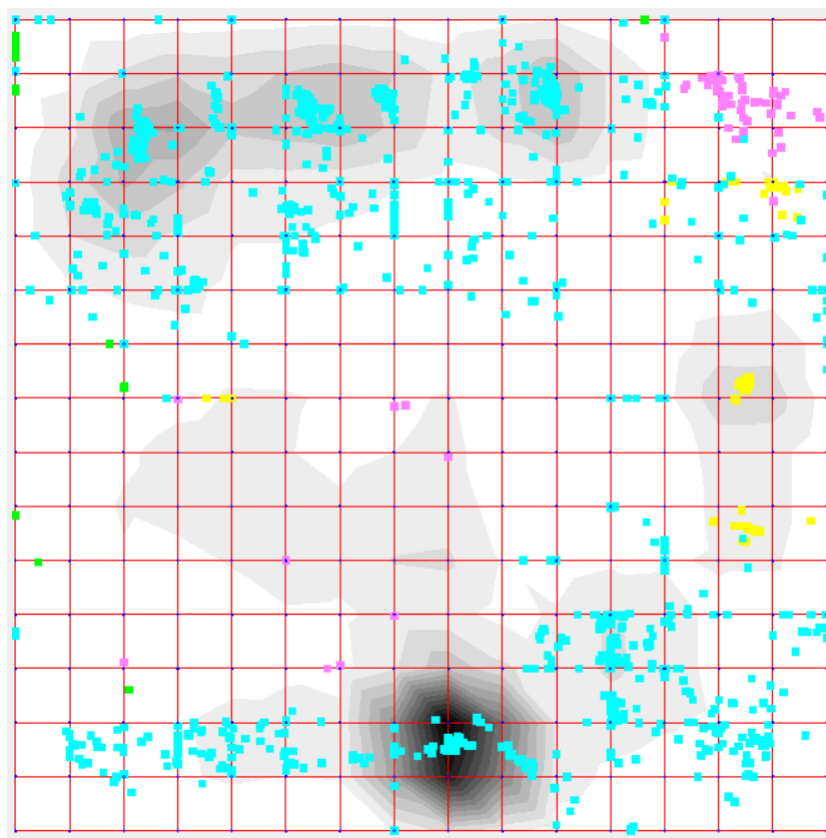


Рис. 1. Распределение генов 5S РНК четырех отделов по упругой карте

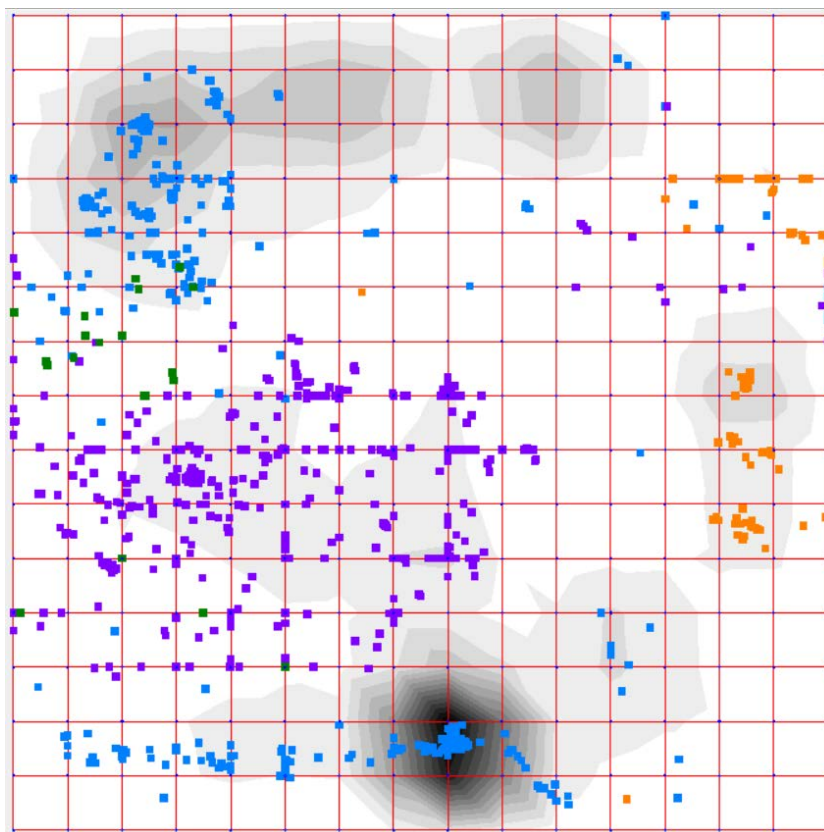


Рис. 2. Распределение генов 16S РНК четырех отделов по упругой карте












Рис.3. Совместное распределение генов 5S и 16S РНК четырех отделов по упругой карте

На рисунке 3 показан результат кластеризации генов 5S и 16S РНК бактерий методом упругих карт. Напомним, что сравнительное исследование этих генов и есть основной результат нашей работы. На этом рисунке точки, соответствующие каждому из отделов, перечисленных в таблице 1, показаны своим цветом (см. таблицу 2)

Таблица 2


Расшифровка цветовой кодировки отделов бактерий,
рассмотренных в работе

Отдел	5S	16S
<i>Actinobacteriota</i>		
<i>Bacteroidota</i>		
<i>Firmicutes</i>		
<i>Verrucomicrobiota</i>		

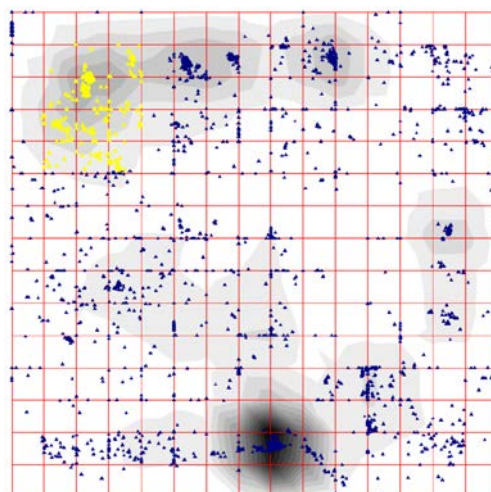
Для сравнения распределения генов 5S и 16S РНК было выделено шесть кластеров, обозначенных желтым цветом (рисунок 2) и проанализирован их состав: в основном в кластерах сосредоточены представители одного отдела и класса, но представители генов 5S и 16S РНК отличаются по семействам; особый интерес вызывают кластеры 3 и 4, в которых сосредоточены представители отдела *Bacteroidota*, но в третьем кластере представлены гены 5S РНК, а в четвертом – 16S РНК.

Перейдем к описанию основного результата настоящей работы — сравнению кластеризации генов 5S и 16S РНК по триплетному составу. Полученные результаты показывают, что распределение генов 5S РНК коррелирует с таксономическим положением носителей этих генов. Одновременно, изучение совместного распределения генов 5S и 16S РНК по триплетному составу показывает, что указанные классы генов формируют свои собственные (слабо пересекаю-


щиеся) кластеры.




Кластер 1



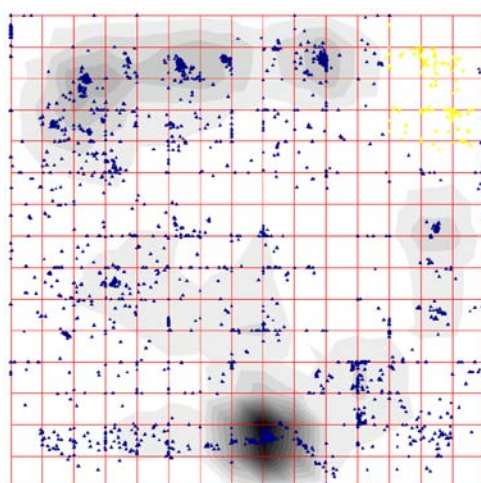
Кластер 2




Кластер 3



Кластер 4



Кластер 5



Кластер 6

Рис. 2. Распределение генов 5S и 16S РНК на 6 кластеров

Полученные результаты также косвенно свидетельствуют о хорошем выявлении связи между структурой (триплетный состав) и функцией генов 5S и 16S РНК.

Список литературы

1. Sadovsky M., Putintseva Yu., Chernyshova A., Fedotova V. Genome structure of organelles strongly relates to taxonomy of bearers // International Conference on Bioinformatics and Biomedical Engineering / Springer. — 2015. — P. 481–490.
2. Gorban A., Popova T., Sadovsky M. Classification of symbol sequences over their frequency dictionaries: towards the connection between structure and natural taxonomy // Open Systems & Information Dynamics. — 2000. — Vol. 7, no. 1. — P. 1–17.
3. A. Teterleva, V. Abramov, A. Morgun, I. Larionova, M. Sadovsky Unsupervised Classification of Some Bacteria with 16S RNA Genes // LNBI, vol.13346, Part I, 2022, pp.205 – 215.
4. Gorban A., Zinovyev A. Principal Manifolds for Data Visualisation and Dimension Reduction // Lecture Notes in Computational Science and Engineering — Berlin – Heidelberg – New York: Springer, 2007. — Vol. 58. — P. 153–176.
5. Gorban A., Zinovyev A. Fast and user-friendly non-linear principal manifold learning by method of elastic maps // 2015 IEEE International Conference on Data Science and Advanced Analytics, DSAA 2015, Campus des Cordeliers, Paris, France, October 19-21, 2015. — 2015. — P. 1–9. — Access mode: <https://doi.org/10.1109/DSAA.2015.7344818>.
6. Gorban A., Zinovyev A. Elastic principal graphs and manifolds and their practical applications // Computing 75, no. 4 (2005): 359-379.
7. Gorban, Alexander N., Alexander Pitenko, and Andrei Zinovyev. "ViDaExpert: user-friendly tool for nonlinear visualization and analysis of multidimensional vectorial data." arXiv preprint arXiv:1406.5550 (2014).

НЕОДНОРОДНОСТЬ РАСПРЕДЕЛЕНИЯ ГЕНОВ ОБЕЗЬЯНЬЕЙ ОСПЫ ПО ТРИПЛЕТНОМУ СОСТАВУ КОРРЕЛИРУЕТ С ИХ ФУНКЦИОНАЛЬНОЙ РОЛЬЮ

Д.О. Путрюков², М.Г. Садовский¹⁻⁴

¹ФГБОУ ВО КрасГМУ им. Проф. В.Ф. Войно-Ясенецкого Минздрава России

²Сибирский федеральный университет

³Институт вычислительного моделирования СО РАН

⁴СНКЦ ФМБА России

В работе представлены предварительные результаты по выявлению упорядоченности среди болезнетворных генов генома обезьяньей оспы, полученные методом динамических ядер. Была выявлена функциональная связь. Показаны особенности применяемых методов, а также представлены выводы по полученным результатам.

В современном биологическом мире огромный интерес представляет изучение структуры геномов. Работа посвящена изучению триплетного состава генома обезьяньей оспы на предмет однородности. Под триплетным составом в данной работе подразумевается частотный словарь всех возможных вариантов триплетов (AAA, AAG, AAC, ..., TTT). Частотный словарь отображает геном в 64-мерном пространстве, из этого пространства можно исключить триплет с наименьшим квадратичным отклонением из-за его слабого влияния на итоговый результат. В данной работе был исключен триплет GCC.

Геном был взят в GenBank банке. Релиз представлен 30 мая 2022 года. Построение классификации методом динамических ядер производилось в программе ViDaExpert.

При построении классификации методом динамических ядер присутствует проблема непостоянства распределения объектов по классам так как каждая итерация начинается со случайного разбиения на классы. Максимальное количество классов определялось эмпирическим путём.

ID	AAA	AAC	AAG	AAT	ACA	ACC	ACG
URK20440	0,0284	0,0217	0,0406	0,0135	0,0271	0,0135	...
URK20441	0,021	0,0229	0,0134	0,0334	0,0277	0,0134	...
URK20442	0,0351	0,0181	0,021	0,0272	0,0283	0,0096	...
URK20443	0,0351	0,013	0,0152	0,0335	0,0175	0,0069	...
URK20444	0,0599	0,023	0,0092	0,0415	0,023	0,0046	...
URK20445	0,0187	0,0211	0,0047	0,0094	0,0258	0,0047	...
URK204..

Рис. 1. Данные перед классификацией.

Вторая проблема состоит в том, что хоть и максимальное количество классов зафиксировано, фактических классов в разы больше, к одинаковым группам относились элементы, которые в каждом повторении кластеризации попадали в одинаковые классы.




Рис. 2. Гибкая карта генов обезьяньей осы.

Подготовка данных включала в себя парсинг всего генома с помощью библиотеки BioPython, анализ нуклеотидных последовательностей генов методом скользящего окна (Sliding window algorithm) и подсчёт процентного содержания триплетов в геноме. Подготовленные данные были введены в таблицу, на основе которой проводилась классификация.

Обзор полученной классификации выявил распределение генов по функциональному признаку. Все наиболее крупные классы содержат в себе болезнетворные, либо ассистирующие им гены. Также были найдены гены кодирующие малоизученные белки. Тот факт, что эти белки относятся к определённым классам, может упростить их дальнейшее изучение.

Список литературы

1. Садовский, М. Г. Восьмикластерная структура геномов хлоропластов наземных растений / М. Г. Садовский, М. Ю. Сенашова, А. В. Малышев // Журнал общей биологии. – 2018. – Т. 79, № 2. – С. 124-134. – EDN YTFQLW.
2. Садовский, М. Г. Информационно-статистический анализ нуклеотидных последовательностей: специальность 03.00.02: диссертация на соискание ученой степени доктора физико-математических наук / Садовский Михаил Георгиевич. – Красноярск, 2004. – 394 с. – EDN NNEUHR.
3. Sadovsky M. G. Information capacity of nucleotide sequences and its applications // Bulletin of mathematical biology. – 2006. – Т. 68. – С. 785-806.
4. Gorban, A. N. Seven clusters in genomic triplet distributions / A. N. Gorban, T. G. Popova, A. Y. Zinovyev // In Silico Biology. – 2003. – Vol. 3, No. 4. – P. 471-482. – EDN LHQBQN.

УПОРЯДОЧЕННОСТЬ ЗНАЧЕНИЙ GC-СОСТАВА ФРАГМЕНТОВ В ПРОСТРАНСТВЕННОЙ СТРУКТУРЕ ГЕНОМОВ ОРГАНЕЛЛ

М.Ю.Сенашова

Институт вычислительного моделирования СО РАН, *msen@icm.krasn.ru*

Введение

Изучение особенностей и деталей структуры нуклеотидных последовательностей является важнейшей задачей биологии в настоящее время. Исследования ведутся в двух аспектах — структурно-функциональном и эволюционном. Выявление связи между структурными компонентами и соответствующим им функциями представляет собой классическую проблему молекулярной и системной биологии и несмотря на обширный поток публикаций и исследований в этом направлении, она всё ещё далека от завершения. Более того, исследователи выявляют всё новые и новые структурные элементы либо новые виды и формы взаимодействий и взаимоотношений между структурными элементами биологических макромолекул, этому способствует развитие техники и инструментов исследований.

Понятна важность таких исследований с точки зрения эволюционных процессов. Изучение особенностей структуры биологических макромолекул у разных организмов позволяет составить более точную картину эволюции тех или иных биологических систем — от вполне конкретных видов до экосистем и глобальных сообществ.

Кроме того, затруднения в исследованиях такого рода всегда вызывают выбор и качество того биологического материала, который берётся в рассмотрение. Дело даже не в ошибках секвенирования и/или аннотирования генетических последовательностей, неизбежных во многих случаях, а в большой сложности таких объектов, как геномы либо отдельные хромосомы. Рассматривая эти объекты, приходится анализировать набор характеристик: структуру, функцию и филогению. Эти характеристики очень сильно взаимодействуют и сильно влияют друг на друга. Причем это влияние далеко не всегда удаётся выделить в каче-

стве отдельного и независимого фактора.

Прокариотические организмы с этой точки зрения являются более удобными объектами для исследования. Очень удобно использовать геномы органелл, в нашем случае — митохондрий и хлоропластов, поскольку для них полностью исключается влияние различий в кодируемых функциях: в пределах одной группы органелл функциональные различия отсутствуют.

GC-состав геномов как в целом, так и отдельных участков очень часто используется в исследованиях структуры геномов и функций отдельных участков. Этому посвящено много работ, как в случае геномов хлоропластов [1-8], так и геномов митохондрий [9-15]. В данной работе мы рассматриваем, как распределяются значения GC-состава выделенных фрагментов геномов хлоропластов и митохондрий в пространственной структуре генома, полученной на основе частотных словарей этих фрагментов.

Материалы и методы

Введем основные понятия. Мы будем рассматривать генетическую последовательность длины L , состоящую из символов алфавита $\aleph = \{A, C, G, T\}$. Для этой последовательности мы будем составлять частотный словарь толщины 3. Частотный словарь W_3 толщины 3 символьной последовательности – это список всех троек $\omega = \nu_1\nu_2\nu_3$ идущих подряд нуклеотидов с указанием частот этих троек; всего может быть 64 триплета. Мы используем частотный словарь, в котором триплеты подсчитываются таким образом, что они полностью покрывают последовательность и при этом не пересекаются. Частота f_ω – это отношение числа копий n_ω данного слова к общему числу всех триплетов N , где N – сумма всех n_ω :

$$f_\omega = \frac{n_\omega}{N} \quad (1)$$

Всякий частотный словарь W_3^3 отображает геном в 64-мерное метрическое пространство.

Один из 64 триплетов исключался, поскольку сумма всех частот в словаре

равна 1, что порождает линейную связь, которая будет давать ложный сигнал при статистической обработке (корреляционном анализе, определении главных компонент и т.п.).

В нашем случае целесообразнее исключить тот триплет, для которого стандартное отклонение, наблюдаемое по анализируемому набору частотных словарей, является минимальным: такой триплет дает наименьший вклад в различимость объектов (в предельном случае, когда стандартное отклонение равно 0, различий по этому триплету вовсе нет). Таким образом, рассматриваемое нами пространство точек становится 63-мерным.

Для выявления структуры в генетической последовательности проводилась предварительная обработка, которая ставила в соответствие данной последовательности множество точек в 63-мерном пространстве триплетов. Делалось это следующим образом: последовательность сканировалась рамкой считывания длины Δ с шагом t . Для каждого положения i рамки определялся участок генетической последовательности, совпадающий с рамкой считывания, для которого вычислялся частотный словарь $W_3^{(i)}$ соответствующий i -ой точке в 63-мерном пространстве. Кроме того, с каждой точкой в 63-мерном пространстве связывались следующие параметры: номер центрального символа рассматриваемого участка и GC-состав этого участка. Номер центрального символа участка совпадает с номером этого символа в последовательности.

Данные для исследования брались в базе EMBL-банка. Было отобрано 418 геномов митохондрий растений и животных, в среднем по 25 видов на кладу и 391 геном хлоропластов наземных растений. Для всех генетических последовательностей длина рамки считывания $\Delta = 603$, шаг $t = 11$.

По полученному множеству точек в программе VidaExpert (<http://bioinfo-out.curie.fr/projects/vidaexpert/>) строился вид данных в пространстве первых трех главных компонент, вычисленных для данного 63-мерного пространства. Рассматривались две проекции на плоскость пространства главных компонент: 1-ой и 2-ой компоненты и 1-ой и 3-ей компоненты или 2-ой и 3-ей компоненты, в зависимости от структуры генома. В обеих проекциях точки окрашивались в соот-

ветствии со значениями GC-состава. Для GC-состава окраска выполнялась следующим образом. Строилась гистограмма по величине GC-состава. Все точки в интервале изменения GC-состава делились на семь примерно равных частей пропорционально количеству точек с соответствующими значениями. Точки, распределенные по семи интервалам, раскрашивались в соответствии с цветами радуги. Минимальным значениям GC-состава соответствует фиолетовый цвет, максимальным – красный. Указанные цвета используются для всех рисунков ниже по тексту.

Пространственная структура величины GC-состава фрагментов геномов хлоропластов.




Рис. 1. Пространственное расположение GC-состава фрагментов генома *Anthoceros angustus* в пространстве 1 и 2 главных компонент (рис. 1 а) и 2 и 3 главных компонент (рис. 1 б)

Было рассмотрено 391 геномов хлоропластов из базы EMBL. Как было показано в [16], подавляющее большинство геномов хлоропластов наземных растений имеет восьмикластерную структуру генома. Шесть кластеров, соответствующих относительным фазам, образуют три луча в пространстве второй и третьей главных компонент. Центральное место занимает кластер, соответствующий

некодирующим участкам. Кроме того, в пространстве первой и второй главных компонент виден восьмой кластер, так называемый «хвост» (рис. 1а слева). На рис 1 а, б показана структура генома хлоропласта с раскрашенным распределением величины GC-состава на примере генома *Anthoceros angustus* (идентификатор AB086179 в EMBL). Исключен триплет gcg. Было обнаружено, что распределение величины GC-состава фрагментов генома по пространственной структуре однотипно. GC-состав фрагментов распределен по градиенту вдоль оси симметрии пространственной структуры генома – от меньших значений к большим, причем минимальные значения находятся в вершине трехлучевой структуры, а максимальные – в отдельно расположенном кластере, так называемом «хвосте» (рис. 1 а).

Пространственная структура величины GC-состава фрагментов геномов митохондрий.

Пространственная структура геномов митохондрий имеет преимущественно трехлучевую структуру. Но встречаются и другие типы структур. Для части геномов не представляется возможным выделить какую-либо упорядоченность в структуре пространственного расположения точек, соответствующих фрагментам генома. Мы не можем сказать определенно, является ли это особенностью данных геномов, или ошибками секвенирования. Кроме того, наземные растения и печеночные мхи имеют структуру близкую к эллипсоиду. Рассмотрим группы геномов, для которых наблюдается однотипное распределение значений GC-состава по пространственной структуре геномов.

Рассмотрим сначала геномы митохондрий растений и печеночных мхов, как наиболее отличающихся ото всех остальных геномов митохондрий. Как уже было сказано выше, для наземных растений и печеночных мхов характерна структура геномов митохондрий эллипсоидной формы. Для их геномов характерно ярко выраженное градиентное распределение значений GC-состава вдоль оси симметрии структуры. На рис. 3 показано распределение значений GC-состава *Zea mays* (идентификатор AB251495 в EMBL, исключен триплет gcg).

Как видно из рисунка, наблюдается градиентное распределение значений GC -состава фрагментов вдоль оси симметрии структуры генома. Аналогично выглядит структура генома и распределение GC -состава для печеночных мхов.




Рис. 3. Пространственное расположение GC -состава фрагментов генома *Zea mays* в пространстве 1 и 2 главных компонент (рис. 3 а) и 2 и 3 главных компонент (рис. 3 б).

Для всех остальных геномов митохондрий характерна трехлучевая структура и далее отдельно это указываться не будет.

Для одноклеточных водорослей, обычных мхов, мхоподобных лишайников из рода *Cladonia* и высших грибов характерно градиентное распределение значений GC -состава фрагментов вдоль оси симметрии структуры генома. На рис.4 показано распределение значений GC -состава фрагментов на примере *Mesostigma viride* (идентификатор AF353999 в EMBL, исключен триплет *ccg*), *Physcomitrella patens* (идентификатор AY506529 в EMBL, исключен триплет *ccg*), *Cladonia petrophila* (идентификатор MG941021 в EMBL, исключен триплет *ccg*) и *Agaricus bisporus var. bisporus H97* (идентификатор MG941021 в EMBL, исключен триплет *gcg*).

Многоклеточные водоросли, лишайники и низшие грибы не имеют ярко выраженного градиентного распределения. Тем не менее, можно заметить, что минимальные значения GC -состава располагаются большей частью на одном конце оси симметрии структуры, а максимальные на другом. Распределение GC -

состава фрагментов по структуре геномов показано на рис. 5 на примере *Saccharina japonica* (идентификатор AP011493 в EMBL, исключен триплет *cgc*), *Hyrogymnia vittata* (идентификатор KY362374 в EMBL, исключен триплет *cgc*), *Candida viswanathii* (идентификатор EF536359 в EMBL, исключен триплет *cgc*).




Рис. 4. Пространственное расположение GC-состава фрагментов генома *Mesostigma viride* в пространстве 1 и 3 главных компонент (рис. 4 а), *Physcomitrella patens* в пространстве 2 и 3 главных компонент (рис. 4 б), *Cladonia petrophila* в пространстве 1 и 3 главных компонент (рис. 4 в) и *Agaricus bisporus var. bisporus H97* в пространстве 1 и 3 главных компонент (рис. 4 г).




Рис. 5. Пространственное расположение GC -состава фрагментов генома *Saccharina japonica* (рис. 5 а), *Hypogymnia vittata* (рис. 5 б) и *Candida viswanathii* (рис. 5 в) в пространстве 1 и 3 главных компонент.

Перейдем к рассмотрению геномов митохондрий животных.

Для геномов митохондрий насекомых, паукообразных и ракообразных характерно центральносимметричное распределение значений GC -состава фрагментов по пространственной структуре геномов. Минимальные значения GC -состава расположены в центре трехлучевой структуры геномов, максимальные по краям. Промежуточные значения не имеют ярко выраженной градации по значениям, но большинство точек предыдущего интервала значений находится ближе к центру, чем большинство точек следующего интервала. На рис. 6 показано центральносимметричное распределение значений GC -состава на примере *Homalodisca vitripennis* (идентификатор AY875213 в EMBL, исключен триплет *cgg*), *Liphistius erawan* (идентификатор JQ407803 в EMBL, исключен триплет

cgg) и *Trigoniophthalmus alternatus* (идентификатор EU016193 в EMBL, исключен триплет *gcg*).




Рис. 6. Пространственное расположение *GC*-состава фрагментов генома *Homalodisca vitripennis* (рис. 6 а), *Liphistius erawan* (рис. 6 б) и *Trigoniophthalmus alternatus* (рис. 6 в) в пространстве 1 и 2 главных компонент.

Следующую группу геномов составляют губки, моллюски, плоские, кольчатые и круглые черви. Для геномов этой группы встречаются распределение значений *GC*-состава в виде неявного градиентного распределения, центрально-симметричное и отсутствие какого-то выраженного распределения. На рис. 7 представлены все варианты на примере *Callyspongia plicifera* (идентификатор EU237477 в EMBL, исключен триплет *cgc*), *Neritina usnea* (идентификатор

KU342665 в EMBL, исключен триплет *cgc*) *Urechis caupo* (идентификатор AY619711 в EMBL, исключен триплет *gcg*), *Echinococcus equinus* (идентификатор AF346403 в EMBL, исключен триплет *cgc*)




Рис. 7. Пространственное расположение GC -состава фрагментов генома *Callispongia plicifera* (рис. 10 а) в пространстве 1 и 3 главных компонент., *Neritina usnea* (рис. 10 б), *Urechis caupo* (рис. 10 в) и *Echinococcus equinus* (рис. 10 г) в пространстве 1 и 2 главных компонент.

Для позвоночных животных не удалось выявить какую-либо типичную картину распределения GC -состава фрагментов внутри классов и между классами.

Выводы.

Результаты, описанные в статье, показывают, что существует упорядочен-

ность в распределении значений GC-состава фрагментов различных геномов. Причем эта упорядоченность имеет типичный вид для отдельных групп геномов. Наибольшим разнообразием в типах распределений GC-состава фрагментов обладают геномы митохондрий. Особо хочется отметить случаи, когда тип распределения соответствует не собственному классу геномов, а более высокому по уровню классу. Это относится к печеночным мхам и мхоподобным лишайникам рода *Cladonia*. Можно сделать предположение, что они представляют собой промежуточные эволюционные ступени.

Список литературы

1. Shimda H., Sugiuro M. Fine structural features of the chloroplast genome: comparison of the sequenced chloroplast genomes //Nucleic acids research. – 1991. – Т. 19. – №. 5. – С. 983-995.
2. Young H. A. et al. Chloroplast genome variation in upland and lowland switchgrass //PloS one. – 2011. – Т. 6. – №. 8. – С. e23980.
3. Lockhart P. J. et al. Controversy on chloroplast origins //FEBS letters. – 1992. – Т. 301. – №. 2. – С. 127-131.
4. Gao L. et al. Complete chloroplast genome sequence of a tree fern *Alsophila spinulosa*: insights into evolutionary changes in fern chloroplast genomes //BMC evolutionary biology. – 2009. – Т. 9. – №. 1. – С. 130.
5. Wu Z. Q., Ge S. The phylogeny of the BEP clade in grasses revisited: evidence from the whole-genome sequences of chloroplasts //Molecular phylogenetics and evolution. – 2012. – Т. 62. – №. 1. – С. 573-578.
6. Qian J. et al. The complete chloroplast genome sequence of the medicinal plant *Salvia miltiorrhiza* //PloS one. – 2013. – Т. 8. – №. 2. – С. e57607.
7. Zhang T. et al. The complete chloroplast and mitochondrial genome sequences of *Boea hygrometrica*: insights into the evolution of plant organellar genomes //PLoS One. – 2012. – Т. 7. – №. 1. – С. e30531.
8. Yang Y. et al. Comparative analysis of the complete chloroplast genomes of

- five *Quercus* species //Frontiers in plant science. – 2016. – T. 7. – C. 959.
9. Behura S. K. et al. Complete sequences of mitochondria genomes of *Aedes aegypti* and *Culex quinquefasciatus* and comparative analysis of mitochondrial DNA fragments inserted in the nuclear genomes //Insect biochemistry and molecular biology. – 2011. – T. 41. – №. 10. – C. 770-777.
 10. Johnston I. G., Williams B. P. Evolutionary inference across eukaryotes identifies specific pressures favoring mitochondrial gene retention //Cell systems. – 2016. – T. 2. – №. 2. – C. 101-111.
 11. Ferla M. P. et al. New rRNA gene-based phylogenies of the Alphaproteobacteria provide perspective on major groups, mitochondrial ancestry and phylogenetic instability //PLoS One. – 2013. – T. 8. – №. 12. – C. e83383.
 12. Nakamura Y. et al. The first symbiont-free genome sequence of marine red alga, *Susabi-nori* (*Pyropia yezoensis*) //PloS one. – 2013. – T. 8. – №. 3. – C. e57122.
 13. Godel C. et al. The genome of the heartworm, *Dirofilaria immitis*, reveals drug and vaccine targets //The FASEB Journal. – 2012. – T. 26. – №. 11. – C. 4650-4661.
 14. Imanian B. et al. Tertiary endosymbiosis in two dinotoms has generated little change in the mitochondrial genomes of their dinoflagellate hosts and diatom endosymbionts //PLoS One. – 2012. – T. 7. – №. 8. – C. e43763.
 15. Wei L. et al. Analysis of codon usage bias of mitochondrial genome in *Bombyx mori* and its relation to evolution //BMC evolutionary biology. – 2014. – T. 14. – №. 1. – C. 262.
 16. Michael G. Sadovsky, Maria Yu Senashova, Andrew V. Malyshev1 Amazing symmetrical clustering in chloroplast genomes // BMC Bioinformatics, 2020, 21(Suppl 2):83

ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ И ИСКУССТВЕННЫЕ НЕЙРОННЫЕ СЕТИ: ВОСПРИЯТИЕ ШКОЛЬНИКОВ (НА ПРИ- МЕРЕ ОБРАЗОВАТЕЛЬНОЙ СМЕНЫ ЛАГЕРЯ «АРТЕК»)

В.А. Углев
Сибирский федеральный университет

Проблема осознания роли и возможностей искусственного интеллекта в современном мире затрагивает детей школьного возраста даже раньше, чем они начинают изучать программирование. Это мотивировано не только широкой доступностью телефонов, компьютеров и интернета, но и агрессивным информационным фоном из средств массовой информации, интернет-рекламы и иных информационных ресурсов. Любопытно посмотреть на то, как школьники воспринимают искусственный интеллект как научно-техническую область деятельности, а также роль и место в ней искусственных нейронных сетей. Для этой цели обратимся к результатам исследования аудитории образовательной смены лагеря «Артек».

Знаменитый ФГБОУ «Международный детский центр «Артек» [1] организует инновационно-образовательную деятельность для отдыхающих в нем школьников (это называется «образовательные смены»). Одна из таких смен в июле 2023 г. организовывала цикл образовательных лекций под эгидой движения «Первые» [2]. Для этого приглашались преподаватели, которые в течение четырех дней работали с учащимися (от 2-х академических часов в день) по различным областям наук. Программу занятий каждый преподаватель разрабатывал сам, а школьники сами записывались на понравившуюся. В описываемой смене одновременно проводились занятия по экологии, истории, робототехнике, энергетике, космическим аппаратам, химии и искусственному интеллекту (ИИ). В доступе были аудитории с проектором/телевизором и ноутбуки (для практических занятий) с доступом к интернету (рис 1, слева).



Рис. 1. Аудитория (слева) и схема вложенности тем в ИИ (справа).

Интерес к искусственному интеллекту у организаторов был не случаен: мало того, что это одна из ключевых технологий шестого технологического уклада [3], его успехи широко освещаются в средствах массовой информации и будоражат умы многих школьников при выборе будущей профессии. При этом следует отметить, что освящение ИИ в основном касается успехов искусственных нейронных сетей (ИНС всех типов, но особенно их приложения к обработке/синтезу изображений и текстов). Но так как ИНС не является единственным подходом в ИИ, то, как отмечалось на последнем заседании Российской ассоциации искусственного интеллекта (РАИИ, Москва, декабрь 2022), не следует сводить эту науку к нейросетям, как это было сделано, например, в документе [4] (см. рис 1, справа). По этой причине было принято решение посмотреть на информированность учащихся в следующих аспектах:

1. понимание границ и многообразия методов ИИ (в целом, а также деля их на методы восходящего и нисходящего подходов);
2. степень акцентированности аудитории на ИНС как ведущем методе ИИ.

Важно было оценить восприимчивость школьников к теме ИИ для последующей организации результативной контактной работы. Это было сделано в два этапа: проведение анкетирования и теста начальных знаний. Ответы фиксировались в электронной среде AESU [5], позволяющей строить компетентностные профили [6].

Дадим характеристику контингенту. Из 70 человек анкету прошли 37, а тест – 64 человека (оба этапа были добровольны). Среди респондентов соотно-

шение юношей и девушек составило 39 к 25. Возрастное распределение: 38% в возрасте 16 лет, 33 – 15 лет, остальные (12,13,14,17) – 29%. Региональное распределение было преимущественно представлено европейской частью России (только 4 школьника, среди заполнивших анкету, проживали за Уралом). Следует отметить, что респонденты были не среднестатистическими учащимися: это были активисты, имеющие достижения и обучающиеся на хорошие отметки. При этом они не входили в специализированные смены по техническим или информационным наукам, т.е. попали на трек «Искусственный интеллект» по интересу (так заявили 70% респондентов), против 27%, которые указали интерес к теме с позиции будущей специализации обучения.

Результаты анкетирования. Введем следующую последовательность методов ИИ, являющихся наиболее представительными в рамках направления: искусственные нейронные сети (А, все типы); экспертные/рекомендательные системы (Б, все типы); онтологии и семантические сети (В); эволюционные вычисления (Г, включая генетические алгоритмы и роевой интеллект); Data Mining (Д, включая data visualization); нечёткая логика (Е); многоагентные системы (Ж). Вариант «Затрудняюсь ответить», «Не знаком», «Не встречался» обозначим через «З». Ответы «А»-«Ж» можно было отмечать в любой комбинации, при выборе «З» иные ответы не принимались. Ответы на избранные вопросы приведены в таблице 1: значения приведены в процентах по группе.

Таблица 1.

Ответы респондентов на избранные вопросы анкеты

Вопрос	Метод ИИ							
	А	Б	В	Г	Д	Е	Ж	З
Укажите базовые методы ИИ, которые Вам доводилось встречать в повседневной жизни?	67	10	0	10	8	8	0	27
Как Вы считаете, какая из технологий ИИ, на ваш взгляд, обладает наибольшей перспективой?	83	2	0	10	0	2	0	-

Укажите, про какие методы ИИ вы слышите впервые?	0	55	89	62	75	65	82	21
Укажите, про какие методы ИИ вам бы хотелось узнать больше?	60	27	40	53	60	60	40	-

Тестирование начальных знаний включало в себя батарею тестовых заданий закрытой формы и позволяло выбирать вариант ответа «Затрудняюсь ответить» (его рекомендовалось отмечать в случае затруднений). Распределение набранных баллов для 100-балльной шкалы за тест начальных знаний показано на рис. 2 (слева). Средний балл по группе составил 32%. Несмотря на то, что респонденты в своём большинстве пытались игнорировать рекомендации и угадывать ответы там, где они не владели материалом (более половины), экспертная оценка «честности» по критерию Шортлиффа [7] показала для группы следующее распределение (см. рис. 2, справа). Значения критерия приведено в шкале от -1 (не угадывал) до 1 (отвечал честно). Более подробно методика оценки и формирования компетентностного профиля приведена в [8].




Рис. 2. Распределение значений набранных баллов по группе за тест (% , слева) и оценки попыток угадывания ответов (справа).

Теперь обратимся к цели нашего исследования и посмотрим на то, каков был результат проверки следующих гипотез:

- способен воспринимать всё многообразие методов ИИ как единую отрасль знаний (*a*);

- владеть общим представлением о методах нисходящего подхода (кон-

цептуализации знаний, б).

- владеть общим представлением о методах восходящего подхода (машинном обучении, в);

- ожидать от технологии ИНС создания «сильного» ИИ (переоценка, г).

На рис. 3 показаны результаты проверки этих четырех гипотез, обобщенные по группе: ось абсцисс – интервалы со значениями коэффициента уверенности от -1 до 1 (опровергается и подтверждается, соответственно; 0 - неопределенность); ось ординат – доли (проценты), принадлежащие каждому интервалу.

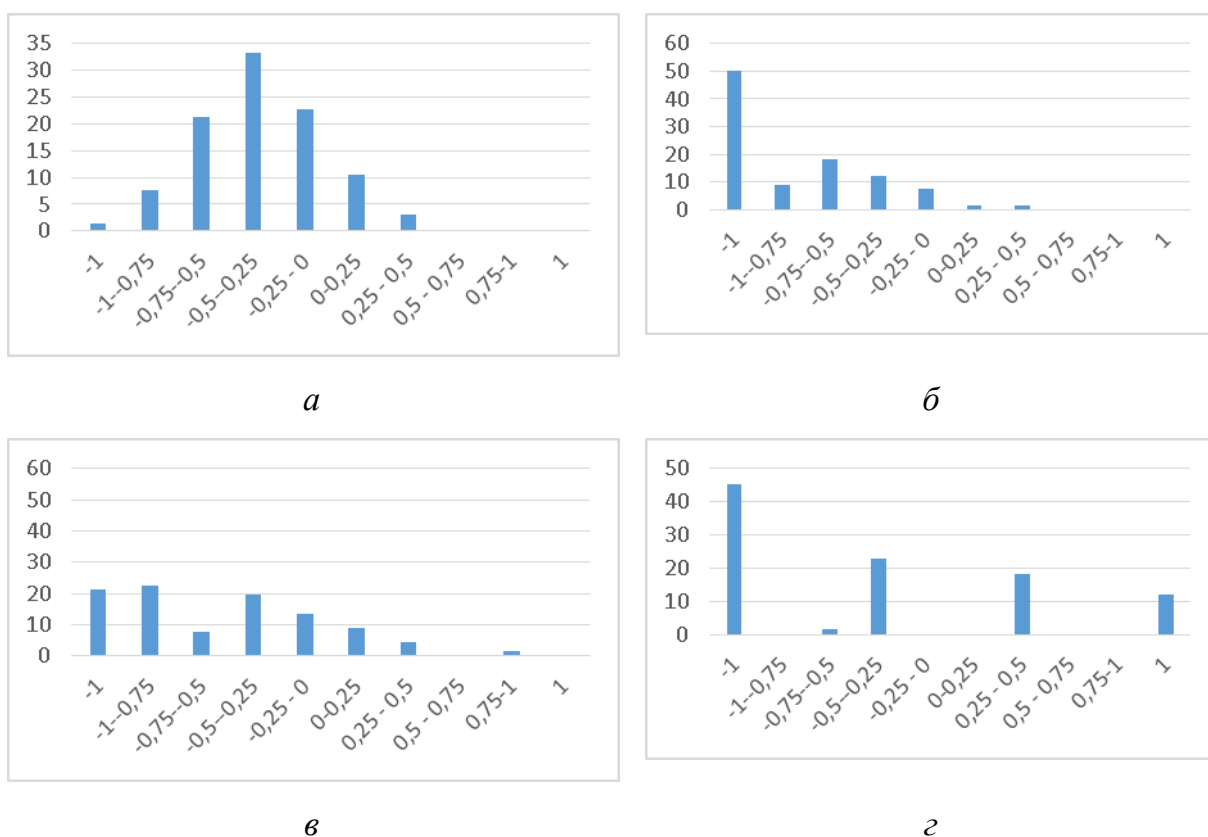


Рис. 3. Доли значений результатов проверки гипотез

Индивидуально подобная оценка строилась по ряду гипотез (8 штук), формируя компетентностный профиль. Например, для одного из учащихся компетентностный профиль до (слева) и после (справа) прослушивания курса приведен на рис. 4. Значения оценок гипотез а-г с рис. 3 соответствуют осям 2,3,4 и 8 на диаграмме-звезде. В отличие от входного контроля, во втором случае попытки

угадывания носили систематический характер, поэтому значения оценок будем считать немного завышенными. Несмотря на это, уровень понимания предмета повысился.




Рис. 4. Примеры компетентностного профиля одного из учащихся до и после прослушивания курса

Практическими выводами из исследования для проведения занятий стали следующие утверждения:

1. повышенная информированность аудитории в области ИНС позволяет сместить акцент на иные методы ИИ (полезно будет дать учебный материал с позиции инженерии знаний, включая практику, и рассказать обо всех методах);

2. завышенные ожидания от ИИ и непонимание масштабов его воздействия нуждаются в разъяснении и «развеивании мифов» (будет полезен обзор и обсуждение ограничений возможностей как ИИ в целом, так и методов, связанных с ИНС).

На основании этого был сформирован краткий курс «Искусственный интеллект», включающий в себя темы, представленные в табл. 2. Акцент был сделан на методы нисходящего подхода не только потому, что о ИНС у аудитории было больше знаний, но и по тому, что организация практики в сжатом временном интервале не могла быть гарантированно обеспечена вычислительными ресурсами и стабильным каналом сети интернет. Позднее выяснилось, что занятия следующей «волны» с приглашенными экспертами (через 5 дней) включали самостоятельный краткий курс нейронных сетей (также на 8 академических часов за 4 дня работы).

Таблица 2.

Тематический план краткого курса

№	Тема	Форма	Часы.
1	ИИ как направление развития научного прогресса	Лекция	1
2	Методы восходящего подхода в искусственном интеллекте	Лекция	1
3	Инженерия знаний	Лекция	0,5
4	Методы нисходящего подхода в искусственном интеллекте	Лекция	1
5	«Мифология» и реальность в применении ИИ	Лекция	0,5
6	Субъективные знания и метод нечёткой логики	Практика	1
7	Практика проектирования рекомендательных систем	Практика	3

После прочтения теоретического (лекционного) блока школьникам было предложено разделить на группы по 3-4 человека и поработать с ноутбуками. Для первичного знакомства с методом нечёткой логики [9] использовался табличный процессор MS Excel. Не смотря на удобство работы с этой программой для организации наглядных расчётов и построения графиков характеристических функций, сложилось впечатление, что многие школьники (особенно в возрасте до 16 лет) работали в программе впервые.

Блок практической работы по рекомендательным системам приводился в сервисе FLM_Builder v 4.1b [10]. Это онлайн конструктор продукционных экспертных систем с элементами нечёткой логики. На рис. 5 (слева) представлено окно конструктора с графом решений и характеристические функции одного из нечётких множеств (взято из [11]). Как показала практика, школьники достаточно быстро освоили интерфейс системы и успели не только сформировать модель экспертной системы (рис. 5, справа) в формате *.flm, но и использовать её в проекте на языке Python.

Анкетирование и практическая работа показали, что 75,6% респондентов уже владеют основами языка Python. Но даже некоторым новичкам удалось ин-

тегрировать flm-модель в свой проект, используя со страницы <https://aesfu.ru/method/flm-builder/instructions/> модуль интеграции моделей продукционных экспертных систем *FLM_Model.py* и подробное руководство для программиста.

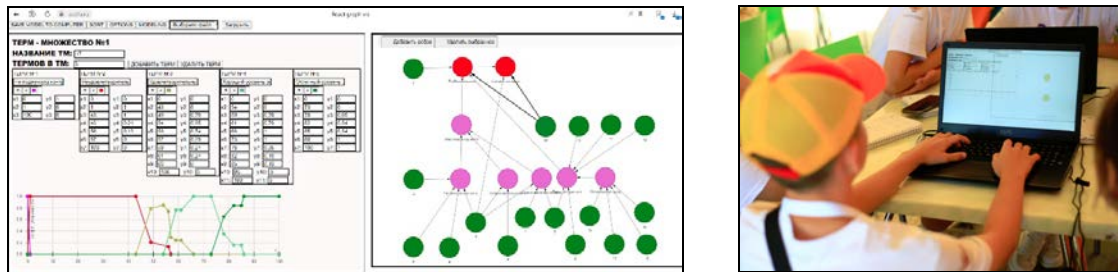


Рис. 5. Окно сервиса FLM_Builder v 4.1b (слева) и работа в нём учащихся смены (справа).

К сожалению, получить полноценную обратную связь от всего контингента учащихся по окончании курса не удалось: учащиеся в большинстве своём проигнорировали просьбу на прохождение итогового теста. В результате был зафиксирован повышение оценки за итоговый тест в среднем до 68,7 баллов (против среднего в 32,06 баллов на входном контроле при большей выборке). Учитывая непрфильность смены и достаточную сложность рассматриваемых тем курса, мы считаем эти результаты положительными.

Возвращаясь к тому, что объектом исследования было восприятие школьниками ИИ и ИНС, то следует отметить следующее: во-первых, важно при первом знакомстве с ИИ давать общую рамку этого научного направления, не делая акцент в сторону методов нисходящего или восходящего подхода; во-вторых, наряду с достоинствами и возможностями ИНС следует объяснять их ограничения; в-третьих, обсуждение должно вестись с позиции реальных возможностей ИИ, объясняя несостоятельность многих «мифов», касающихся этого направления.

Автор выражает благодарность организаторам от «Движения первых» за возможность принять участие в смене и предоставление фотографий с занятий в лагере.

Список литературы

1. Официальный сайт Федеральное государственное бюджетное образовательное учреждение «Международный детский центр «Артек»: <https://artek.org/>.

2. Официальный сайт Общероссийского общественно-государственного Движения детей и молодежи «Движение первых»: <https://будьвдвижении.рф/>.
3. Глазьев С. Ю., Львов Д. С., Фетисов Г. Г. Эволюция технико-экономических систем: возможности и границы централизованного регулирования. — М.: Наука, 1992. — 207 с.
4. Указ Президента РФ от 10.10.2019 N 490 "О развитии искусственного интеллекта в Российской Федерации" (Включает "Национальную стратегию развития искусственного интеллекта на период до 2030 года"): www.consultant.ru/document/cons_doc_LAW_335184/.
5. Сайт экспериментальной интеллектуальной автоматизированной обучающей системы «AESFU»: <https://aesfu.ru/>.
6. Uglev V., Shangina E. Assessment and visualization of course-level and curriculum-level competency profiles // Computational Science and Its Applications – ICCSA 2023 Workshops. LNCS, vol 14104. Springer, Cham. pp. 478–493. https://doi.org/10.1007/978-3-031-37105-9_32.
7. Углев В.А. Проверка гипотезы об уровне развития компетентности с использованием критерия Шортлиффа и Бьюкенена // Нейроинформатика, ее приложения и анализ данных: XXV Всероссийский семинар. – Красноярск, 2017. – С. 96-100.
8. Uglev V.A., Ustinov V.A. The new competencies development level expertise method within Intelligent Automated Educational Systems // Trends in Practical Applications of Heterogeneous Multi-Agent Systems. The PAAMS Collection. Advances in Intelligent Systems and Computing, - 2014. – Vol. 293. – pp. 157-164. DOI 10.1007/978-3-319-07476-4_19.
9. Zadeh L. Fuzzy Sets. Information and Control, 8(3), June 1965. – pp. 338-353.
10. Болсуновский Н.А., Пронин А.Д., Углев В.А. Конструктор производственных экспертных систем с элементами нечёткой логики FLM_Builder и интеграция его моделей в пользовательские проекты // Нейроинформатика, ее приложения и анализ данных: XXX Всероссийский семинар. — Красноярск: ИВМ СО РАН. — 2022. — С. 24-33.
11. Углев В.А. Реализация механизма принятия решений в интеллектуальной автоматизированной обучающей системе на базе модуля экспертных систем // XXI национальная конференция по искусственному интеллекту с международным участием (КИИ-2023). – Смоленск: Изд-во МЭИ, 2023 (в печати).

**ИСПОЛЬЗОВАНИЕ КОМПЬЮТЕРНЫХ НЕЙРОННЫХ СЕТЕЙ ДЛЯ
УЧЕТА ГЕНЕТИЧЕСКИХ ОСОБЕННОСТЕЙ ПАЦИЕНТОВ ПРИ
ПРОВЕДЕНИИ РЕАБИЛИТАЦИИ ПОСЛЕ ОСТРОГО
ИНФАРКТА МИОКАРДА**

С.Е.Головенкин¹, С.Е.Русал², Е.Ю.Можейко¹, И.В.Савицкий¹, Д.В.Ружилов¹

¹ФГБОУ ВО «Красноярский Государственный Медицинский Университет им.
проф. В.Ф.Войно-Ясенецкого» МЗ РФ,

²КГБУЗ «Краевая Клиническая Больница»

Сердечно-сосудистые заболевания являются ведущей причиной смерти в большинстве экономически развитых стран мира. Примерно половина из них – обусловлена ишемической болезнью сердца. Инфаркт миокарда – наиболее грозное проявление ИБС нередко приводящее к летальному исходу. В связи с этим во всем мире постоянно совершенствуются методы оказания помощи этой категории больных. Важнейшими направлениями в этой работе является совершенствование первичной профилактики, улучшение медикаментозного лечения, внедрение в работу высокотехнологичных методов оказания помощи. Особое место в этом процессе занимает кардиореабилитация. Добавление реабилитационных мероприятий к другим методам оказания помощи больным острым инфарктом миокарда позволило в течение года снизить сердечно-сосудистую смертность на 26%, общую смертность на 20%, увеличить полное или частичное восстановление работоспособности с 49% до 79%. В настоящее время в большинстве государств кардиореабилитации пациентов, перенёсших инфаркт миокарда, уделяется большое внимание. Современная система реабилитации пациентов начинается сразу после поступления пациента в реанимационное отделение и продолжается после выписки пациента из клиники на амбулаторном этапе в течение года. Выделяют три этапа реабилитации: ранний стационарный, стационарный реабилитационный и поликлинический реабилитационный. На каждом этапе обязательными компонентами являются медикаментозное и инструментальное воздействие, психологическая помощь и физические методы реабилитации. Под последними понимают постепенное расширение физической активно-

сти пациента после инфаркта миокарда и поддержание её на адекватном уровне в дальнейшем. Особенно важным является физический компонент реабилитации на третьем – амбулаторно-поликлиническом этапе. Именно на этом этапе важно к адекватной медикаментозной и психологической помощи добавить дозированную ходьбу, лечебную физкультуру, тренировки на велоэргометре или тредмиле. В настоящее время в зависимости от возраста, сопутствующей патологии, тяжести перенесенного инфаркта миокарда разработаны схемы увеличения физических нагрузок для каждого пациента. Что позволяет учесть особенности каждого пациента и подобрать ему адекватный уровень физической нагрузки. В тоже время, было замечено, что при одинаковой тяжести инфаркта миокарда, одинаковой сопутствующей патологии реабилитационные мероприятия дают иногда разную эффективность. Что обоснованно позволило предположить влияние генетических особенностей пациентов на эффект реабилитационных мероприятий.

Учитывая эту информацию, для оценки влияния генетических особенностей пациента на восстановление сократительной способности миокарда при проведении реабилитационных мероприятий у больных, перенесших острый инфаркт миокарда, нами отобраны два однонуклеотидные полиморфизма: rs1805126 гена *SCN5A* и rs16847897 гена *LRRC31*.

Примененные нами компьютерные нейронные сети помогли выявить значимость выявленных полиморфизмов в восстановлении сократительной способности миокарда при проведении реабилитационных мероприятий у больных, перенесших острый инфаркт миокарда.

В исследовании мы анализировали информацию 278 пациентов обоего пола в возрасте от 41 до 65 лет, перенесших острый инфаркт миокарда, прошедших полный курс реабилитационных мероприятий, подписавших информированное согласие. Согласно поставленным задачам исследования нами проведено молекулярно-генетическое тестирование образцов ДНК, выделенных из венозной крови пациентов. (анализировался полиморфизм rs1805126).

В остром периоде инфаркта миокарда все пациенты получали лечение в Региональном сосудистом центре/первичных сосудистых отделениях с использо-

ванием чрескожных коронарных вмешательств. Амбулаторно-поликлинический этап реабилитации все пациенты проходили в «Профессорской клинике» Красноярского Государственного медицинского университета и ООО «Центр Современной Кардиологии» (г.Красноярск).

Всем обследуемым проведены клиничко-инструментальные исследования (ЭКГ, эхокардиография, холтеровское ЭКГ-мониторирование, тест с физической нагрузкой, тест с шестиминутной ходьбой), лабораторные исследования. Всем пациентам произведен забор крови на молекулярно-генетическое исследование.

Выделение геномной ДНК из периферической крови проводили методом фенолхлороформной экстракции с модификациями.

Прогнозирование выполнялось при помощи системы Matlab 2016, модуль Neural Network Toolbox. В ходе исследования выполнялся подбор архитектуры нейронной сети, наилучшим образом предсказывающей исходы, описанные в базе данных.

Во всех экспериментах для прогнозирования использовались искусственные нейронные сети прямого распространения (функция *feedforwardnet*). Нейросеть, создаваемая при помощи этой функции, содержит набор из нескольких слоев. Первый (входной) слой связывает сеть с вектором входных данных. Далее располагаются несколько скрытых слоев нейронов, причем каждый последующий слой соединен с предыдущим. Последний (выходной) слой производит расчет одного либо нескольких выходного сигналов сети. Выполнялось обучение нейронной сети с учителем с использованием функции обучения *trainidx*, выполняющей обучение по методу обратного распространения ошибки с оптимизацией функции ошибки методом градиентного спуска.

Восстановление сократительной способности миокарда – важнейшая задача проведения все трех этапов реабилитации после перенесенного острого инфаркта миокарда. Оценку восстановления насосной функции сердца мы оценивали после проведения третьего (амбулаторно-поликлинического) этапа. Третий этап проводится амбулаторно в режиме дневного стационара, начинается через 4-6 недель после перенесенного инфаркта миокарда и продолжается в течение

14-16 дней.

Нами было проведено молекулярно-генетическое тестирование образцов ДНК, выделенных из венозной крови пациентов.

При анализе полиморфизма rs1805126 гена *SCN5A* распределение частот генотипов было следующим: гомозиготный генотип AA - 50,46%, гетерозиготный генотип AG – 33,81%, гомозиготный генотип GG – 15,83%. Данная информация отражена в Таблице 1.

Таблица 1

Распределение частот генотипов полиморфизма rs1805126 гена *SCN5A*

Генотип	Число пациентов	Все пациенты	Мужчины	Женщины
AA	140	50,46%	50,89%	48,15%
AG	94	33,81%	34,82%	29,63%
GG	44	15,83%	14,29%	22,22%
Всего:	278	100,00%	100,00%	100,00%

У мужчин гомозиготный генотип AA составил 50,89%, гетерозиготный генотип AG – 34,82%, гомозиготный генотип GG – 14,29%. У женщин гомозиготный генотип AA составил 48,15%, гетерозиготный генотип AG – 29,63%, гомозиготный генотип GG – 22,22%. Данная информация отражена в Таблице 1.

Восстановление сократительной способности нами оценивалось по пяти показателям: толерантности к физической нагрузке при проведении велоэргометрии, уровню нагрузки при проведении велотренировок, увеличении фракции выброса при проведении ЭхоКГ после проведения кардиореабилитации, приросту показателей теста с шестиминутной ходьбой после прохождения реабилитации, снижении количества баллов по модифицированной шкале Борга после курса реабилитационных мероприятий (шкала оценивает уровень одышки пациента при физической нагрузке). Средние значения этих показателей отражены в Таблице 2.

Таблица 2.

Средние значения показателей восстановления сократительной способности миокарда пациентов генотипов AA, AG, GG полиморфизма rs1805126 гена

SCN5A

Показатель	AA (1)	AG (2)	GG (3)	Значимость различий
Толерантность к ФН, ВЭМ, (Вт)	94.26±5.96	87.55±5.74	69.00±5.40	p ₁₋₂ <0,01, p ₁₋₃ <0,01, p ₂₋₃ <0,01
Тренирующая нагрузка при проведении велотре- нировок(Вт)	74.21±5.50	68.77±4.26	56.05±3.56	p ₁₋₂ <0,01, p ₁₋₃ <0,01, p ₂₋₃ <0,01
Прирост ФВ, ЭхоКС (%)	3.64±1.76	2.39±1.26	0.16±0.48	p ₁₋₂ <0,01, p ₁₋₃ <0,01, p ₂₋₃ <0,01
Прирост ТШХ (м)	55.13±9.45	46.62±7.50	24.45±3.90	p ₁₋₂ <0,01, p ₁₋₃ <0,01, p ₂₋₃ <0,01
Снижение кол-ва баллов, шкала Борга	0.91±0.28	0.79±0.41	0.48±0.21	p ₁₋₂ <0,01, p ₁₋₃ <0,01, p ₂₋₃ <0,01

Как видно из данных Таблицы 2 пациенты с генотипом AA статистически значимо отличаются по всем пяти показателям от пациентов с генотипами AG и GG, кроме того пациенты с генотипом AG статистически значимо по всем пяти показателям отличаются от больных с генотипами AA и GG. Таким образом, генотип AA обладает условно протективным эффектом в сравнении с генотипами AG и GG, а генотип GG ухудшает восстановление сократительной способности миокарда в сравнении с генотипами AG и AA.

Мы провели анализ влияния аллелей A и G полиморфизма rs1805126 гена *SCN5A* на восстановление сократительной способности миокарда. Информация по данному вопросу содержится в Таблице 3.

Таблица 3

Средние значения показателей восстановления сократительной способности миокарда у пациентов с аллелями A и G полиморфизма rs1805126 гена *SCN5*

Показатель	аллель A	аллель G	Значимость различий

Толерантность к ФН ВЭМ, (Вт)	92.57±6.57	78.58±10.83	p<0,05
Тренирующая нагрузка при проведении велотренировок, (Вт)	72.84±5.71	62.62±7.48	p<0,05
Прирост ФВ, ЭхоКС, (%)	3.32±1.73	1.31±1.48	p<0,05
Прирост ТШХ, (м)	52.99±9.71	35.9±12.63	p<0,05
Снижение кол-ва баллов, шкала Борга	0.88±0.32	0.41±0.49	p<0,05

Как видно из Таблицы 3 пациенты имеющие аллель G имеют статистически значимые различия в сравнении с пациентами, имеющие только аллель А по показателям: толерантность к физической нагрузке при проведении велоэргометрии, уровень нагрузки при проведении велотренировок, увеличение фракции выброса при проведении ЭхоКГ после проведения кардиореабилитации, прирост показателей теста с шестиминутной ходьбой после прохождения реабилитации, снижение количества баллов по модифицированной шкале Борга после курса реабилитационных мероприятий. Таким образом, есть основания полагать, что имеется ассоциация наличия аллеля G с ухудшением восстановления сократительной способности миокарда у пациентов, проходящих курс кардиореабилитации после перенесенного острого инфаркта миокарда.

Таким образом, по результатам нашего исследования выяснено, что имеется ассоциация наличия у пациентов генотипа GG полиморфизма rs1805126 гена *SCN5A* и ухудшения восстановления сократительной способности миокарда у пациентов после курса реабилитационных мероприятий. Кроме того, наблюдается ассоциация наличия аллеля G и ухудшения восстановления сократительной способности миокарда у пациентов, проходящих курс кардиореабилитации после перенесенного острого инфаркта миокарда.

Применение компьютерных нейронных сетей позволило выяснить, что добавление информации о наличии генотипа GG полиморфизма rs1805126 гена *SCN5A* позволяет повысить точность восстановления сократительной способно-

сти миокарда при проведении реабилитационных мероприятий у больных, перенесших острый инфаркт миокарда с 84,6% до 92,7%.

Внедрение полученных в данном исследовании результатов позволит на основании генетических особенностей пациента индивидуально подойти к выбору физической нагрузки при проведении велотренировок в рамках проведения реабилитации пациентов после перенесенного острого инфаркта миокарда. Это позволит улучшить восстановление сократительной способности миокарда и уменьшить вероятность развития хронической сердечной недостаточности в дальнейшем. Что в свою очередь улучшит качество жизни пациента и уменьшит финансовые затраты здравоохранения и социальных служб на оказание помощи пациентам с данной патологией.

Внедрение персонального подхода к пациенту с учетом его генетических особенностей позволит оптимизировать процесс восстановления сократительной способности миокарда во время реабилитационных мероприятий и уменьшит в дальнейшем вероятность неблагоприятного течения заболевания (в т.ч. снизит вероятность развития хронической сердечной недостаточности (ХСН)). Это будет еще одним компонентом решения серьезной отраслевой проблемы – проблемы профилактики и лечения пациентов ХСН, которая требует серьезных финансовых затрат в бюджете здравоохранения.

СПИСОК ДОКЛАДОВ

А.Е. Алехина, Толмачев Е. В., М.Г. Доррер МОНИТОРИНГ СОБЫТИЙ ВЗВЕШИВАНИЯ ТРАНСПОРТА НА АВТОМОБИЛЬНОЙ ВЕСОВОЙ С ПРИМЕНЕНИЕМ ИНСТРУМЕНТОВ КОМПЬЮТЕРНОГО ЗРЕНИЯ	3
Н.М. Богатов, А.Н. Богатова, С.А. Сухих СПОСОБНОСТЬ УПРАВЛЕНИЯ СОСТОЯНИЕМ ОРГАНИЗМА МУЖЧИН И ЖЕНЩИН	13
А.Д.Богдашевская, А.В.Бахшиев ПРИМЕНЕНИЕ ГЛУБОКИХ НЕЙРОННЫХ СЕТЕЙ ДЛЯ ПОВЫШЕНИЯ КАЧЕСТВА ОБНАРУЖЕНИЯ ДВУМЕРНЫХ МАТРИЧНЫХ ШТРИХ-КОДОВ В СИСТЕМАХ ВИДЕОАНАЛИТИКИ	21
А.В.Бойко, А.В.Бахшиев, А.М. Корсаков АППАРАТНАЯ РЕАЛИЗАЦИЯ СЕГМЕНТНОЙ СПАЙКОВОЙ МОДЕЛИ НЕЙРОНА CSNM НА ОПЕРАЦИОННЫХ УСИЛИТЕЛЯХ	31
А.В. Бутусов, Хайдер Али Хуссейн Алавси, С.А. Филист, В.В. Песок, А.Е. Пшеничный НЕЙРО-НЕЧЕТКАЯ СЕТЬ ДЛЯ ОПРЕДЕЛЕНИЯ СТЕПЕНИ ТЯЖЕСТИ ВНЕБОЛЬНИЧНОЙ ПНЕВМОНИИ	42
И.А Демичев, В.В. Сакович, М.Г. Садовский, С.Д. Гусев ОПРЕДЕЛЕНИЕ ПОКАЗАТЕЛЕЙ ДМПП С ПОМОЩЬЮ МАШИННОГО ОБУЧЕНИЯ	50
Т.Т.Исаков, А.В.Бахшиев, А.М. Корсаков РЕШЕНИЕ ЗАДАЧИ КЛАССИФИКАЦИИ С ИСПОЛЬЗОВАНИЕМ СЕГМЕНТНОЙ СПАЙКОВОЙ МОДЕЛИ НЕЙРОНА НА ПЛИС	54

А.О.Кириличев, Н.А.Болсуновский КОНСТРУИРОВАНИЕ И РЕАЛИЗАЦИЯ ЭКСПЕРТНОЙ СИСТЕМЫ ПО ВАЛИДАЦИИ ПОЛЬЗОВАТЕЛЕЙ НА ОСНОВЕ ТЕКСТОВОГО СЛЕДА	66
А.А. Кузьмин, Часиб Хасан Аль- Дарраджи, С.А. Филист, А.Ю. Сухомлинов ДВУМЕРНОЕ СПЕКТРАЛЬНОЕ ПРЕОБРАЗОВАНИЕ УОЛША В СИСТЕМАХ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА КЛАССИФИКАЦИИ УЛЬТРАЗВУКОВЫХ ИЗОБРАЖЕНИЙ	73
С.В.Листопад, А.С.Лучко МЕТОД ВЫРАБОТКИ СТРАТЕГИИ ПОВЕДЕНИЯ ПРИ ПЕРЕГОВОРАХ ИСКУССТВЕННЫХ ГЕТЕРОГЕННЫХ ИНТЕЛЛЕКТУАЛЬНЫХ АГЕНТОВ РЕФЛЕКСИВНО-АКТИВНЫХ СИСТЕМ	83
А.В. Медиевский, С.В. Кириллова, А.Г. Зотин, К.В. Симонов, А.С. Кургляков АНАЛИЗ ЭЛЕКТРОЭНЦЕФАЛОГРАММ ПАЦИЕНТОВ С ЭПИЛЕПСИЕЙ НА ОСНОВЕ ВЕЙВЛЕТ-ПРЕОБРАЗОВАНИЙ	91
Ю.И.Овчинникова, М.Г.Садовский СРАВНИТЕЛЬНЫЙ АНАЛИЗ КЛАСТЕРИЗАЦИИ ГЕНОВ 5S И 16S РНК ПО ТРИПЛЕТНОМУ СОСТАВУ	101
Д.О. Путрюков, М.Г. Садовский НЕОДНОРОДНОСТЬ РАСПРЕДЕЛЕНИЯ ГЕНОВ ОБЕЗЬЯНЬЕЙ ОСПЫ ПО ТРИПЛЕТНОМУ СОСТАВУ КОРРЕЛИРУЕТ С ИХ ФУНКЦИОНАЛЬНОЙ РОЛЬЮ	109

М.Ю.Сенашова	
УПОРЯДОЧЕННОСТЬ ЗНАЧЕНИЙ GC-СОСТАВА ФРАГМЕНТОВ В ПРОСТРАНСТВЕННОЙ СТРУКТУРЕ ГЕНОМОВ ОРГАНЕЛЛ	112
В.А. Углев	
ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ И ИСКУССТВЕННЫЕ НЕЙРОННЫЕ СЕТИ: ВОСПРИЯТИЕ ШКОЛЬНИКОВ (НА ПРИМЕРЕ ОБРАЗОВАТЕЛЬНОЙ СМЕНЫ ЛАГЕРЯ «АРТЕК»)	124
С.Е.Головенкин, С.Е.Русал, Е.Ю.Можейко, И.В.Савицкий, Д.В.Ружилов	
ИСПОЛЬЗОВАНИЕ КОМПЬЮТЕРНЫХ НЕЙРОННЫХ СЕТЕЙ ДЛЯ УЧЕТА ГЕНЕТИЧЕСКИХ ОСОБЕННОСТЕЙ ПАЦИЕНТОВ ПРИ ПРОВЕДЕНИИ РЕАБИЛИТАЦИИ ПОСЛЕ ОСТРОГО ИНФАРКТА МИОКАРДА	133

СПИСОК АВТОРОВ

Ф.И.О.	Место работы	Стр.
Алавси Хайдер Али Хусейн	305044, г. Курск, ул.50 лет Октября, 94, Юго-Западный государственный университет E-mail: book.hp.2015@gmail.com	42
Алехина Анна Евгеньевна	660000, Красноярск, просп. Имени газеты Красноярский Рабочий, 31, Сибирский государственный университет науки и технологий им. М.Ф. Решетнева E-mail: a.tolmacheva@solutionfactory.ru	3
Аль-Дарраджи Часиб Хасан	305044, г. Курск, ул.50 лет Октября, 94, Юго-Западный государственный университет E-mail: chasibaboody@gmail.com	73
Бахшиев Александр Валерьевич	195251, Санкт-Петербург, Политехническая ул., 29, Санкт-Петербургский политехнический университет Петра Великого E-mail: palexab@gmail.com	21, 31, 54
Богатов Николай Маркович	350040, г. Краснодар, ул. Ставропольская, 149 ФГБОУ ВО «Кубанский государственный университет» E-mail: bogatov@phys.kubsu.ru	13
Богатова Анна Николаевна	350040, г. Краснодар, ул. Ставропольская, 149 ФГБОУ ВО «Кубанский государственный университет» E-mail: anna_bogatova@mail.ru	13
Богдашевская Александра Дмитриевна	195251, Санкт-Петербург, Политехническая ул., 29, Санкт-Петербургский политехнический университет Петра Великого E-mail: alexandra_bogdashevskaya@mail.ru	21
Бойко Александр	195251, Санкт-Петербург, Политехническая ул., 29,	31

Васильевич	Санкт-Петербургский политехнический университет Петра Великого E-mail: boyko02av@mail.ru	
Болсуновский Николай Александрович	662971, Железногорск, ул. Кирова, 12-а, Сибирский федеральный университет, филиал г. Железногорска E-mail: bz990@ya.ru	66
Бутусов Андрей Владимирович	305044, г. Курск, ул.50 лет Октября, 94, Юго-Западный государственный университет E-mail: mustang2004@vist.ru	42
Головенкин Сергей Евгеньевич	660022, Красноярск, ул. Партизана Железняка, 1, ФГБОУ ВО «Красноярский Государственный Медицинский Университет им. проф. В.Ф.Войно-Ясенецкого» МЗ РФ, E-mail: gse2008@mail.ru	133
Гусев Сергей Дмитриевич	660022, Красноярск, ул. Партизана Железняка, 1, Красноярский государственный медицинский университет имени профессора В.Ф.Войно-Ясенецкого E-mail: sdg53@rambler.ru	50
Демичев Игорь Анатольевич	660022, Красноярск, ул. Партизана Железняка, 1, Красноярский государственный медицинский университет имени профессора В.Ф.Войно-Ясенецкого E-mail: igordemicev08788@gmail.com	50
Доррер Михаил Георгиевич	660000, Красноярск, просп. Имени газеты Красноярский Рабочий, 31, Сибирский государственный университет науки и технологий им. М.Ф. Решетнева E-mail: dorrer_mg@sibsau.ru	3
Зотин Александр Геннадьевич	660000, Красноярск, просп. Имени газеты Красноярский Рабочий, 31, Сибирский государственный университет науки и технологий им. М.Ф. Решетнева	91

	E-mail: zotin@sibsau.ru	
Исаков Тим Тимурович	195251, Санкт-Петербург, Политехническая ул., 29, Санкт-Петербургский политехнический университет Петра Великого E-mail: t.isakov@rtc.ru	54
Кириличев Александр Олегович	662971, Железногорск, ул. Кирова, 12-а, Сибирский федеральный университет, филиал г. Железногорска E-mail: kirilichev.a@icloud.com	66
Кириллова Светлана Владимировна	660041, г. Красноярск, проспект Свободный, 79, Сибирский федеральный университет, ИКИТ E-mail: svkirillova2009@yandex.ru	91
Корсаков Антон Михайлович	194064, Санкт-Петербург, Тихорецкий пр., д. 21, Центральный научно-исследовательский и опытно-конструкторский институт робототехники и технической кибернетики (ЦНИИ РТК) E-mail: a.korsakov@rtc.ru	31, 54
Кругляков Алексей Сергеевич	660036, г. Красноярск, Академгородок, Институт вычислительного моделирования СО РАН E-mail: piggsyy@gmail.com	91
Кузьмин Александр Алексеевич	305044, г. Курск, ул.50 лет Октября, 94, Юго-Западный государственный университет E-mail: ku3bmin@gmail.com	73
Листопад Сергей Викторович	236022, Калининградская область, г. Калининград, ул Гостиная, 5, Калининградский филиал федерального государственного учреждения "Федеральный исследовательский центр "Информатика и управление" Российской академии наук E-mail: ser-list-post@yandex.ru	83
Лучко Александр	236013, Калининградская область, город Калининград, Магнитогорская ул., д. 4а, ООО «Автотор ин-	83

Сергеевич	формационные технологии» E-mail: luchko@inbox.ru	
Медиевский Алексей Владимирович	660022, Красноярск, ул. Партизана Железняка, 1, Красноярский государственный медицинский университет имени профессора В.Ф.Войно-Ясенецкого E-mail: amedievsky@yandex.ru	91
Можейко Елена Юрьевна	660022, Красноярск, ул. Партизана Железняка, 1, ФГБОУ ВО «Красноярский Государственный Медицинский Университет им. проф. В.Ф.Войно-Ясенецкого» МЗ РФ, E-mail: el_mozhejko@mail.ru	133
Овчинникова Юлия Игоревна	660041, Красноярск, Свободный пр., 82А, Сибирский федеральный университет, ИФБиБТ E-mail: july.l4o6@mail.ru	101
Песок Валерия Вячеславовна	305044, г. Курск, ул.50 лет Октября, 94, Юго-Западный государственный университет E-mail: lera.pesok@mail.ru	42
Пшеничный Александр Евгентевич	305044, г. Курск, ул.50 лет Октября, 94, Юго-Западный государственный университет E-mail: lera.pesok@mail.ru	42
Путрюков Дмитрий Олегович	660041, г. Красноярск, проспект Свободный, 79, Сибирский федеральный университет E-mail: putrukovd@gmail.com	109
Ружилов Дмитрий Вячеславович	660022, Красноярск, ул. Партизана Железняка, 1, ФГБОУ ВО «Красноярский Государственный Медицинский Университет им. проф. В.Ф.Войно-Ясенецкого» МЗ РФ, E-mail: dmitrii_ruzhilov@mail.ru	133
Русал Светлана Евгеньевна	660022, г. Красноярск, ул. Партизана Железняка, 3а, КГБУЗ «Краевая Клиническая Больница» E-mail: rusal_se@mail.ru	133

Савицкий Иван Владимирович	660022, Красноярск, ул. Партизана Железняка, 1, ФГБОУ ВО «Красноярский Государственный Медицинский Университет им. проф. В.Ф.Войно-Ясенецкого» МЗ РФ, E-mail: idontknown@mail.ru	133
Садовский Михаил Георгиевич	660036, Красноярск, Академгородок, Институт вычислительного моделирования СО РАН E-mail: msad@icm.krasn.ru	50, 101, 109
Сакович Виталий Валерьевич	660022, Красноярск, ул. Партизана Железняка, 1, Красноярский государственный медицинский университет им. Проф. В.Ф. Войно-Ясенецкого Минздрава России E-mail: sakovichvitaly@gmail.com	50
Сенашова Мария Юрьевна	660036, Красноярск, Академгородок, Институт вычислительного моделирования СО РАН E-mail: msen@icm.krasn.ru	112
Симонов Константин Васильевич	660036, Красноярск, Академгородок, Институт вычислительного моделирования СО РАН E-mail: simonovkv@icm.krasn.ru	91
Сухих Станислав Алексеевич	350040, г. Краснодар, ФГБОУ ВО «Кубанский государственный университет», ул. Ставропольская, 149 E-mail: suhих_52@mail.ru	13
Сухомлинов Артем Владимирович	305044, г. Курск, ул.50 лет Октября, 94, Юго-Западный государственный университет E-mail: sukhomlinovua@kursksmu.net	73
Толмачев Евгений Викторович	Самозанятый E-mail: tolmachev9@gmail.com	3
Углев Виктор Александрович	662971, Железногорск, ул. Кирова, 12-а, Сибирский федеральный университет, филиал г. Железногорска	124

	E-mail: uglev-v@yandex.ru	
Филист Сергей Алексеевич	305044, г. Курск, ул.50 лет Октября, 94, Юго- Западный государственный университет E-mail: SFilist@gmail.com	42, 73

Научное издание

Нейроинформатика, её приложения и анализ данных

Материалы XXXI Всероссийского семинара 29 сентября 2023 года

Редактор М.Ю. Сенашова
Компьютерная верстка: М.Ю. Сенашова

Подписано в печать «15» августа 2023 г. Формат 60 × 90/8. (А4)
Бумага офсетная. Печать плоская.
Усл. печ. л. 11,0. Уч.-изд. л. 11,3.
Тираж 500 экз. Заказ 12

Отпечатано в типографии ИВМ СО РАН
660036, Красноярск, Академгородок