

Федеральное государственное бюджетное образовательное учреждение
высшего образования
«Томский государственный университет систем управления и
радиоэлектроники» (ТУСУР)

На правах рукописи

Светлаков Михаил Олегович
МЕТОД И АЛГОРИТМЫ АНАЛИЗА ДАННЫХ
ЭЛЕКТРОЭНЦЕФАЛОГРАФИИ ДЛЯ ВЕРИФИКАЦИИ СУБЪЕКТА
Специальность 2.3.8
«Информатика и информационные процессы»

Диссертация на соискание учёной степени
кандидата технических наук

Научный руководитель:
доктор технических наук, профессор
Ходашинский Илья Александрович

Томск 2023

Оглавление

Введение.....	5
Глава 1. Задача верификации субъекта на основе данных электроэнцефалограммы... ..	16
1.1 Электроэнцефалограмма	16
1.2 Использование данных электроэнцефалограммы в задачах машинного обучения	21
1.3 Методы обработки данных электроэнцефалограммы и извлечения признаков.....	23
1.4 Верификация субъекта на основе ЭЭГ.....	27
1.5 Интерпретируемые методы и модели машинного обучения.....	32
1.6 Нечеткие классификаторы	35
1.7 Метрическое обучение.....	40
1.8 Постановка задачи верификации.....	42
1.9 Выводы	44
Глава 2. Метод и алгоритмы верификации субъекта на основе данных электроэнцефалограммы	47
2.1 Построение базы правил нечеткого классификатора с использованием кластеризации и метаэвристического алгоритма “стая птиц”.....	47
2.1.1 Предобработка данных ЭЭГ.	47
2.1.2 Извлечение признаков из сигнала ЭЭГ.....	48
2.1.3 Алгоритм-аналог для построения базы правил нечеткого классификатора на основе экстремальных значений признаков.....	48
2.1.4 Метаэвристический алгоритм “стая птиц”	50
2.1.5 Алгоритм-аналог генерации базы правил нечеткого классификатора кластеризацией	53

2.1.6	Определение числа кластеров на основе алгоритма Autonomous Data Partitioning	54
2.1.7	Алгоритм построения базы правил нечеткого классификатора с использованием кластеризации и метаэвристического алгоритма “стая птиц”	57
2.2	Алгоритм отбора признаков с использованием функции трансформации и метаэвристического алгоритма “стая птиц”	59
2.3	Метод верификации субъекта на основе данных электроэнцефалограммы с использованием извлечения признаков на основе преобразования Холо-Гильберта и метрического обучения	62
2.3.1	Архитектура модели-аналога на основе дискретного вейвлет-преобразования	62
2.3.2	Архитектура модели-аналога на основе преобразования Гильберта-Хуанга	63
2.3.3	Метод и архитектура модели верификации субъекта на основе данных электроэнцефалограммы с использованием извлечения признаков на основе преобразования Холо-Гильберта и метрического обучения	66
2.4	Выводы	70
Глава 3. Исследование эффективности разработанных метода и алгоритмов		72
3.1	Используемые наборы данных и предобработка, протоколы оценки	72
3.2	Исследование эффективности построения базы правил нечеткого классификатора кластеризацией с использованием метаэвристического алгоритма “стая птиц”	72
3.3	Исследование эффективности отбора признаков с использованием функции трансформации и метаэвристического алгоритма “стая птиц”	88

3.4 Проверка предложенных алгоритмов отбора признаков и генерации структуры нечеткого классификатора для набора данных ЭЭГ и решения задачи верификации.....	90
3.5 Проверка эффективности верификации субъекта на основе данных электроэнцефалограммы с использованием извлечения признаков на основе преобразования Холо-Гильберта и метрического обучения	92
3.6 Выводы.....	96
Глава 4. Применение предложенных метода и алгоритмов для решения задачи классификации сегментов ЭЭГ и выявления эпилептиформ	99
4.1 Задача классификации сегментов ЭЭГ и выявления эпилептиформ.....	99
4.2 Сбор набора данных и решение задачи с помощью нечетких классификаторов.....	100
4.3 Решение задачи с помощью моделей на основе преобразования Холо-Гильберта.....	105
4.4 Выводы	118
Заключение	120
Литература	123
Приложение А. Точность архитектур на основе метрического обучения и нейронных сетей	145
Приложение Б. Примеры из собранного набора данных для обнаружения эпилептиформ и результаты оценки построенных моделей.....	147
Приложение В. Свидетельства о государственной регистрации программ для ЭВМ..	152
Приложение Г. Акт о внедрении результатов диссертационного исследования в рабочий процесс	155
Приложение Д. Акт о внедрении результатов диссертационного исследования в учебный процесс.....	157

Введение

Системы автоматизированного распознавания субъектов на основе их уникальных физиологических и поведенческих характеристик [1] (таких как отпечатки пальцев, рисунок радужной оболочки глаза, особенности голоса, походки) более удобны для конечного пользователя, поскольку не требуют запоминания сложных паролей или ношения физических жетонов или смарт-карт. В отличие от паролей или физических жетонов, физиологические и поведенческие характеристики всегда находятся при пользователе, их невозможно забыть или потерять. Данные характеристики, как правило, сложнее воспроизвести или подобрать, чем пароли. Рассматриваемые системы на основе физиологических и поведенческих характеристик также имеют свои недостатки. На них могут повлиять изменения в физическом состоянии субъекта (например, травмы, старение), и, в случае утечки контрольного шаблона субъекта, его не получится сменить, в отличие от пароля [2, 3]. Выбор конкретной характеристики для использования влияет на скорость верификации, стоимость и точность получающейся в итоге системы верификации. Научным сообществом предлагаются и исследуются различные физиологические характеристики, например данные электроэнцефалограммы (ЭЭГ) [4]. Данные ЭЭГ представляют собой информацию об электрической активности мозга, и алгоритмы машинного обучения могут анализировать эти данные для выявления закономерностей и решения задач классификации. Данные ЭЭГ нашли применение в различных областях, от интерфейса мозг-компьютер до прогнозирования неврологических расстройств [5]. Уникальность данных ЭЭГ и применимость для верификации многократно подтверждена в работах Zhang S., Lotte F., Maiorana E., Raw-Dowling A., Armstrong B., Ruiz M., Wu Q., Rocca D., Poulos M., Zhi T., Barayeu U., Nishimoto T., Monsy J., Moctezuma L., Kaliramna B., Pham T., Yap H., Suppiah R., Mao Z., Bigdoly A., Jijomon C., Schons T., Das R., Alsumari W. [4-10]. Относительно других характеристик, ЭЭГ имеет ряд потенциальных преимуществ. Сигнал ЭЭГ отражает состояние субъекта в реальном времени, является комплексным и зашумленным,

за счет этого его сложнее подделать, хотя такая возможность существует [11]. Кроме того, системы верификации на основе данных ЭЭГ могут быть интегрированы с другими системами, такими как мониторинг рабочего состояния, для отслеживания усталости [12]. Под верификацией понимается процесс проверки информации путем сопоставления предоставленной информации с ранее подтвержденной информацией [13], сравнение «один к одному» - оценка, вычисление или измерение степени схожести или различия между предоставляемым образцом и контрольным шаблоном [1].

Система верификации субъекта на основе уникальных физиологических и поведенческих характеристик может быть разработана либо на основе вручную определенных экспертами признаков, алгоритмов и правил, либо на основе методов машинного обучения с использованием большого набора физиологических данных с вручную определенными признаками, либо извлекаемых автоматически. В первом случае эффективность системы зависит от способностей человека-эксперта выделить обобщающие признаки и закономерности в большом массиве данных физиологической характеристики, процесс трудоемок и может привести к низкой обобщаемости при вариациях входных данных. Поэтому в современных системах применяются подходы на основе машинного обучения [14]. Анализ существующих систем верификации на основе ЭЭГ выявил, что построенные модели тренируются, в основном, только на predeterminedную группу субъектов. Одной из альтернатив является подход на основе машинного обучения и метрического обучения [14, 15]. В ходе обучения модель обучается преобразовывать входные данные в пространство меньшей размерности, где дистанция соответствует мере схожести представленных контрольных шаблонов, что позволяет более точно верифицировать субъекта [16]. Метрическое обучение также даст способность модели к динамическому обновлению списка субъектов и их шаблонов, а также потенциально может повысить точность системы. Также в ходе анализа выявлено несовершенство используемых протоколов обучения и оценки эффективности моделей

верификации на основе ЭЭГ, что потенциально приводит к более низкой реальной точности, поэтому задача создания алгоритмов и методов верификации субъекта на основе ЭЭГ со скорректированным протоколом обучения и оценки эффективности, а также повышения точности итоговой системы, является актуальной.

Предобработка и преобразование данных является важнейшим этапом обработки сигналов ЭЭГ для повышения точности итоговой модели [17]. Для этой цели могут быть использованы различные методы анализа сигнала, оперирующие во временной области (Time Domain Analysis), оперирующие в частотной области (Frequency Domain Analysis) и оперирующие в частотно-временной области (Time-Frequency Domain Analysis). Одним из перспективных методов выделения признаков ЭЭГ является спектральный анализ Холо-Гильберта (Holo-Hilbert Spectral Analysis, HNSA), который ранее не применялся для задачи верификации субъекта на основе ЭЭГ. HNSA — это метод частотно-временного анализа, который обеспечивает спектральное представление высокого разрешения нестационарных и нелинейных данных, таких как сигналы ЭЭГ. Он расширяет традиционное преобразование Гильберта-Хуанга (Hilbert Huang Transform, HHT) за счет включения "Холо" компоненты, позволяя извлекать из данных информацию как о частотной модуляции сигнала, так и об амплитудной [18].

Использование методов машинного обучения для систем верификации на основе ЭЭГ также представляет собой актуальную проблему в плане интерпретируемости и объяснимости. Модели машинного обучения, особенно такие сложные, как модели глубокого обучения, часто рассматриваются как "черные ящики", поскольку их внутреннее устройство нелегко понять человеку. Такая непрозрачность может стать проблемой во многих приложениях, где очень важно понять, почему было принято то или иное решение [19]. Среди существующих подходов к решению проблемы объяснимости методов машинного обучения (explainable AI, xAI) применяются, в основном, основанные на правилах модели, такие как деревья решений (ансамбли деревьев) или нечеткие системы, либо используются вспомогательные внешние методы, например, на основе

значений Шепли (Shapley additive explanations, SHAP), методы построения вспомогательных моделей или метод интегрированных градиентов (Integrated Gradients, IG) [20]. Нечеткие системы основаны на теории нечетких множеств, которая была введена Лотфи А. Заде в 1965 году [21] как расширение классической теории множеств. Наиболее значимых результатов в изучении нечетких систем достигли уже упомянутый Zadeh L., а также Sugeno M., Takagi T., Bezdek J., Mamdani E., Herrera F., Angelov P., Yager R., Filev D., Аверкин А., Катасёв А., Синюк В., Ярушкина Н., Яхьяева Г. Нечеткие классификаторы имеют в основе принципы человеческого мышления и логики (правила вида ЕСЛИ-ТО), за счет чего более понятны человеку, успешно применяются для решения широкого круга задач машинного обучения [22-25].

При построении нечетких классификаторов зачастую возникает актуальная проблема “проклятия размерности” – экспоненциального возрастания количества данных из-за увеличения размерности пространства признаков [26]. Методы отбора признаков играют ключевую роль в анализе данных и машинном обучении. Они позволяют идентифицировать наиболее информативные и значимые признаки, что приводит к повышению точности моделей и снижению избыточности данных. В случае сигнала ЭЭГ пространство признаков имеет особенно высокую размерность за счет использования большого количества датчиков (каналов) снятия данных, в отдельных случаях их может быть более 100, число признаков кратно возрастает [27]. В случае нечетких классификаторов для отбора признаков зачастую применяются бинаризованные метаэвристические алгоритмы, которые могут учитывать взаимодействие между признаками и их влияние на целевую переменную [28-30]. Использование таких алгоритмов может привести к повышению точности и интерпретируемости нечетких классификаторов за счет снижения избыточности данных.

Цель диссертационной работы - повышение точности и интерпретируемости моделей машинного обучения, предназначенных для верификации субъекта на основе данных электроэнцефалограммы.

Для достижения цели необходимо выполнить следующие **задачи**:

- 1) провести обзор существующих методов верификации субъекта на основе данных электроэнцефалограммы;
- 2) разработать и исследовать метод построения моделей верификации субъекта на основе данных электроэнцефалограммы с помощью нейронных сетей и метода спектрального анализа Холо-Гильберта;
- 3) разработать и исследовать алгоритм формирования структуры нечеткого классификатора с помощью кластеризации и метаэвристических алгоритмов, а также оптимизации параметров нечеткого классификатора;
- 4) разработать и исследовать алгоритм отбора признаков с помощью метаэвристических алгоритмов для нечеткого классификатора;
- 5) провести оценку разработанных алгоритмов на наборах данных ЭЭГ и выполнить сравнение с аналогами.

Объект исследования – процесс построения моделей машинного обучения, предназначенных для верификации субъекта на основе данных электроэнцефалограммы.

Предмет исследования – методы и алгоритмы построения моделей машинного обучения для верификации субъекта на основе данных ЭЭГ.

Методы исследования. В работе применялись методы частотно-временного анализа, классического машинного обучения, глубокого обучения, теория нечетких множеств и нечеткой логики, методы оптимизации.

Достоверность результатов обеспечивается корректностью применения математических методов, результатами проведенных экспериментов и сравнений с базовыми моделями и алгоритмами с помощью статистических критериев.

Научная новизна полученных результатов.

В диссертации получены следующие новые научные результаты.

1. Предложен оригинальный метод верификации субъекта на основе данных электроэнцефалограммы и методов глубокого обучения, отличительной

особенностью которого является извлечение признаков с помощью спектрального анализа Холо-Гильберта и метрического обучения.

2. Разработан гибридный алгоритм построения базы правил нечеткого классификатора, особенностью которого является совместное использование алгоритма кластеризации k -средних и метаэвристического алгоритма “стая птиц”.

3. Разработан алгоритм отбора признаков, особенностью которого является использование V -образной функции трансформации и метаэвристического алгоритма “стая птиц”.

Теоретическая значимость работы заключается в развитии технологии методов извлечения признаков из сигнала ЭЭГ, построения нечетких систем, интеллектуального анализа данных. Предложенный подход на основе данных ЭЭГ и методов глубокого обучения, отличительной особенностью которого является извлечение признаков с помощью спектрального анализа Холо-Гильберта и использования метрического обучения, также может быть использован для решения иных задач классификации данных ЭЭГ. Предложенные оригинальные методы отбора признаков и построения базы правил нечеткого классификатора также могут быть использованы для построения нечетких классификаторов в иных задачах.

Практическая значимость работы подтверждается применением предложенных метода и алгоритмов для решения практической задачи классификации – обнаружения эпилептиформ на сегментах ЭЭГ у пациентов Томского НИИ Курортологии и физиотерапии ФМБА России, получен акт внедрения. Результаты диссертационной работы также внедрены в учебный процесс ТУСУР.

Разработанные метод и алгоритмы использованы при выполнении следующих проектов:

– научный проект при поддержке РНФ проект № 22–21–00021 «Интерпретируемый нечеткий классификатор рукописных данных для диагностики нейродегенеративных заболеваний» 2022–2023 гг.;

– научный проект при поддержке РФФИ № 16–07–00034 «Методы и инструментальные средства построения самообучающихся систем, основанных на нечетких правилах» 2016–2018 гг.

На защиту выносятся следующие положения.

1. Разработанный оригинальный метод верификации субъекта на основе данных ЭЭГ на общедоступном наборе данных Physionet EEG Motor Movement/Imagery Dataset (PEEGMMID) позволяет понизить значение метрики ошибки Equal Error Rate (EER) на 0,97% (с 10,92% до 9,95%; значимые различия по критерию Уилкоксона, $p < 0,01$) по сравнению с использованием признаков на основе преобразования Гильберта-Хуанга, а также снизить значение метрики ошибки EER на 9,38% (значимые различия по критерию Уилкоксона, $p < 0,01$) по сравнению с использованием признаков на основе дискретного вейвлет-преобразования.

Соответствует пункту 4 паспорта специальности: Разработка методов и технологий цифровой обработки аудиовизуальной информации с целью обнаружения закономерностей в данных, включая обработку текстовых и иных изображений, видео контента. Разработка методов и моделей распознавания, понимания и синтеза речи, принципов и методов извлечения требуемой информации из текстов.

2. Разработанный гибридный алгоритм построения базы правил нечеткого классификатора позволяет повысить точность нечеткого классификатора на рассмотренных наборах данных из различных предметных областей в среднем на 14,38% по сравнению с алгоритмом экстремумов признаков классов и на 6,00% по сравнению с алгоритмом на основе кластеризации k -средних. Для проблемы верификации субъекта по ЭЭГ и набора данных PEEGMMID точность классификатора, построенного гибридным алгоритмом, выше точности классификатора на основе машины опорных векторов с линейным ядром на 6,46%, и на 9,37% выше точности нечеткого классификатора, построенного с помощью алгоритма экстремумов признаков классов.

Соответствует пункту 13 паспорта специальности: Разработка и применение методов распознавания образов, кластерного анализа, нейро-сетевых и нечетких технологий, решающих правил, мягких вычислений при анализе разнородной информации в базах данных.

3. Предложенный алгоритм отбора признаков в случае извлеченных с помощью дискретного вейвлет-преобразования признаков и нечеткого классификатора позволил сократить число признаков с 1152 до 98 для набора данных ЭЭГ PEEGMMID.

Соответствует пункту 7 паспорта специальности. Разработка методов обработки, группировки и аннотирования информации, в том числе, извлеченной из сети интернет, для систем поддержки принятия решений, интеллектуального поиска, анализа.

Внедрение результатов диссертационного исследования.

Результаты исследовательской работы использованы для решения практической задачи классификации – обнаружения эпилептиформ на сегментах ЭЭГ пациентов Томского НИИ курортологии и физиотерапии ФМБА России, получен акт внедрения. Результаты диссертационной работы также внедрены в учебный процесс ТУСУР.

Предложенные алгоритмы также использованы при выполнении научного проекта при поддержке РФФ № 22-21-00021 «Интерпретируемый нечеткий классификатор рукописных данных для диагностики нейродегенеративных заболеваний» 2022-2023 гг. и научного проекта при поддержке РФФИ № 16-07-00034 «Методы и инструментальные средства построения самообучающихся систем, основанных на нечетких правилах» 2016–2018.

Апробация работы. Основные положения работы докладывались и обсуждались на конференциях различного уровня. Среди них:

– The Thirteenth International Conference on Swarm Intelligence (ICSI'2022), онлайн, July 15-19 2022, Xi'an, China.

- 2021 IEEE Ural Symposium on Biomedical Engineering, Radioelectronics and Information Technology, онлайн, 13-14 мая 2021;
- Международная научно-техническая конференция студентов, аспирантов и молодых учёных Научная сессия ТУСУР – 2020, Томск, 19–21 мая 2020 г., секция 3.4 “Вычислительный интеллект”;
- Международная научно-техническая конференция студентов, аспирантов и молодых учёных Научная сессия ТУСУР – 2021, Томск, 19–21 мая 2021 г., секция 3.4 “Вычислительный интеллект”;
- XVIII Международная конференция студентов, аспирантов и молодых ученых Перспективы развития фундаментальных наук, Томск, 27-30 апреля 2021;
- Международная научно-техническая конференция студентов, аспирантов и молодых учёных Научная сессия ТУСУР – 2022, Томск, 18–20 мая 2022 г., секция 3.4 “Вычислительный интеллект”;
- XXII Всероссийский ежегодный конкурс-конференция студентов и аспирантов по информационной безопасности SIBINFO-2022, Томск, 27 мая 2022 г.;
- XVIII Международная научно-практическая конференция Электронные средства и системы управления, посвящённая 60-летию ТУСУРа, Томск, 16-18 ноября 2022 г., секция 20 “Вычислительный интеллект и машинное обучение”;
- Международная научно-техническая конференция студентов, аспирантов и молодых учёных Научная сессия ТУСУР – 2022, Томск, 18–20 мая 2023 г., секция 3.4 “Вычислительный интеллект”.

Публикации по теме диссертации. По теме исследования опубликовано 25 печатных работ, из которых в рекомендованных ВАК периодических изданиях – 5. В международной базе SCOPUS проиндексированы 15 работ, 12 работ – в международной базе Web of Science. Получены 3 свидетельства о государственной регистрации программ для ЭВМ.

Личный вклад автора. Диссертантом лично разработаны алгоритмы извлечения признакового набора для сигнала ЭЭГ, формирования структуры

нечеткого классификатора, настройки параметров термов на основе метаэвристики “стая птиц”, алгоритм отбора признаков термов на основе метаэвристики “стая птиц”, разработан метод верификации субъекта на основе данных ЭЭГ, отличительной особенностью которого является извлечение признаков с помощью спектрального анализа Холо-Гильберта и использование метрического обучения; лично получены результаты экспериментов, проведена апробация разработанных алгоритмов. Определение целей и задач исследования, анализ результатов экспериментов, подготовка публикаций по полученным результатам проводились совместно с научным руководителем.

Структура и объем работы. Диссертационная работа состоит из введения, 4 глав основной части, заключения, списка литературы из 199 наименований и 5 приложений. Основная часть работы содержит 157 страниц, в том числе 32 рисунка и 41 таблицу.

Во введении описана актуальность работы, определены цель, задачи, объект, предмет, методы исследования, перечислены основные полученные результаты, их научная новизна, теоретическая и практическая значимость, приведены защищаемые положения.

В первой главе приведен обзор сигнала ЭЭГ, его использования в задачах машинного обучения, применяемые при этом методы обработки сигнала, рассмотрены применяемые и планируемые к применению для решения задачи верификации субъекта на основе данных ЭЭГ модели и методы, поставлена задача верификации.

Во второй главе приведено описание разработанных алгоритмов и метода для решения задачи верификации на основе данных ЭЭГ. Описан оригинальный метод верификации субъекта на основе данных ЭЭГ, отличительной особенностью которого является использование извлечения признаков с помощью преобразования Холо-Гильберта и метрического обучения, описаны соответствующие архитектуры нейронных сетей и моделей-аналогов. Также описан предложенный гибридный алгоритм построения базы правил нечеткого

классификатора, особенностью которого является совместное использование кластеризации на основе метаэвристического алгоритма “стая птиц”, и алгоритм отбора признаков, особенностью которого является использование V-образной функции трансформации и метаэвристического алгоритма “стая птиц”. Описаны алгоритмы-аналоги в случае применения нечетких классификаторов.

Третья глава посвящена проверке эффективности предложенных метода и алгоритмов на наборах данных из репозитория KEEL и на наборе данных ЭЭГ Physionet - PEEGMMID.

В четвертой главе описано применение разработанных метода и алгоритмов для решения задачи обнаружения наличия эпилептиформ на сегментах ЭЭГ.

Автор благодарит за помощь и поддержку в работе над диссертацией научного руководителя, д.т.н., профессора Илью Александровича Ходашинского, а также к.т.н., доцента Константина Сергеевича Сарина и к.т.н., доцента Марину Борисовну Бардамову.

Глава 1. Задача верификации субъекта на основе данных электроэнцефалограммы

1.1 Электроэнцефалограмма

Электроэнцефалограмма представляет собой процедуру исследования работы головного мозга на основе регистрации его электрической активности, отображая колебания потенциалов электрического поля, создаваемых в коре головного мозга, как функцию времени. Полученные в результате временные серии ЭЭГ дают специалистам информацию о нормальной и аномальной мозговой активности. Эти отличительные электрические паттерны делают ЭЭГ полезным диагностическим инструментом для многих заболеваний центральной нервной системы, включая эпилепсию и судороги. Впервые ЭЭГ была применена в 1929 году Гансом Бергером, который опубликовал свои наблюдения о регистрации электрической активности на скальпе головы человека [31]. Последующие исследования позволили расширить понимание электрофизиологии и патологии головного мозга [32]. Электрическая активность возникает в результате химических процессов, происходящих на клеточном уровне, когда нейроны получают и обрабатывают информацию, передаваемую от других нервных клеток в виде электрических импульсов или потенциалов действия. Популяции нейронов, достаточно большие, чтобы производить сигналы ЭЭГ, варьируются примерно от 10^4 до 10^7 нейронов и могут занимать несколько квадратных миллиметров поверхности коры головного мозга [33]. Для снятия сигналов ЭЭГ, зависящих от непрерывных колебаний напряжения в популяциях нейронов, между кожей головы и аппаратом снятия ЭЭГ (шлемом или шапочкой с электродами) устанавливается электрическое соединение с помощью геля или пасты с электролитом. Фактические потенциалы коры головного мозга находятся в диапазоне 500–1500 мВ, но сигналы, записанные со скальпа, намного слабее из-за изолирующего влияния промежуточных тканей (черепной кости). Поэтому прибор для снятия ЭЭГ включает усилители, которые усиливают слабые сигналы и фильтруют

нежелательные помехи, такие как наводки электропитания и другие высокочастотные шумовые сигналы [34].

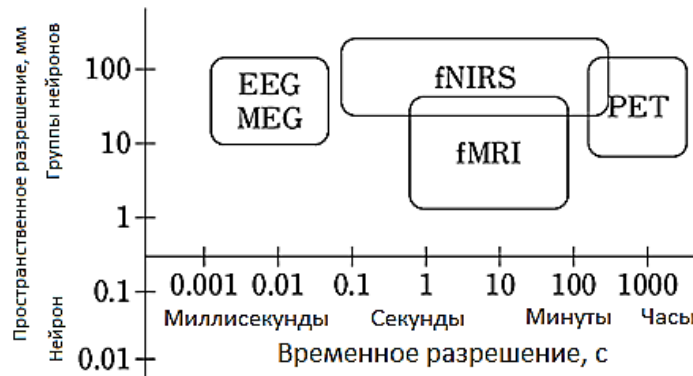


Рисунок 1.1 – Пространственное и временное разрешение некоторых методов регистрации активности головного мозга [35]

Помимо ЭЭГ, существуют и другие методы измерения активности мозга, различающихся пространственно-временным разрешением и применимостью (Рисунок 1.1): электрокортикография (Electrocorticography, ECoG), микроэлектродное снятие потенциалов местного поля; микроэлектродная регистрация отдельных нейронов; позитронно-эмиссионная томография (Positron Emission Tomography, PET), функциональная магнитно-резонансная томография (functional Magnetic Resonance Imaging, fMRI), функциональная спектроскопия в ближнем инфракрасном диапазоне (functional Near-Infrared Spectroscopy, fNIRS), магнитоэнцефалография (Magnetoencephalography, MEG), транскраниальная магнитная стимуляция, транскраниальная стимуляция постоянным током (микрополяризация) [35].

Среди неинвазивных методов можно выделить fMRI, MEG и рассматриваемый метод - ЭЭГ. Эти методы, в целом, хорошо переносятся, применимы в клинической практике и оценивают активность всего мозга в миллиметровом и сантиметровом масштабе. Если сравнивать сигнал ЭЭГ с fMRI, то ЭЭГ имеет более высокое временное разрешение, но низкое пространственное,

а оборудование для снятия ЭЭГ является менее дорогостоящим. На Рисунке 1.2. показан пример сегмента многоканальной записи ЭЭГ.




Рисунок 1.2 – Пример записи ЭЭГ

Частотный диапазон ЭЭГ не имеет четких границ как на нижнем, так и на верхнем из концов спектра. Диапазон клинически значимых частотных компонентов ЭЭГ лежит между 0,1 и 100 Гц, и обычно берется еще более ограниченным - от 0,1 до 70 Гц [36]. Классически выделяют частотные диапазоны называемые ритмами ЭЭГ [37], приведенные в Таблице 1.1.

Таблица 1.1 – Ритмы ЭЭГ

Наименование ритма ЭЭГ	Частотный диапазон	Амплитудный диапазон
Дельта	< 4 Гц	2–200 мВ
Тета	от 4 до 7,5 Гц	≥20 мВ
Альфа	7,5–13 Гц	30–50 мВ
Бета	от 14 до 30 Гц	5–30 мВ
Гамма	30–80 Гц	<5 мВ

Эффективный частотный диапазон может простираться до очень низких частот порядка 0,1 Гц, как для ЭЭГ, так и для МEG. Для верхней границы также, на практике, необходимо учитывать теорему Найквиста-Шеннона-Котельникова [38]. Теорема гласит, что для сигнала, представленного последовательностью дискретных отсчетов, точное восстановление возможно, только если частота дискретизации более чем в 2 раза выше максимальной частоты в спектре сигнала. Частота дискретизации оборудования ЭЭГ варьируется от 128 до 1024 Гц (более низкая частота дискретизации характерна для сухих электродов), чаще находясь в диапазоне 128–256 Гц. На Рисунке 1.3 приведен пример распределения спектральной плотности мощности сигнала ЭЭГ. В области 5–10 Гц всегда выделяется характерный пик. В области 50–60 Гц, если сигнал не отфильтрован, выделяются артефакты – наводки электросети.

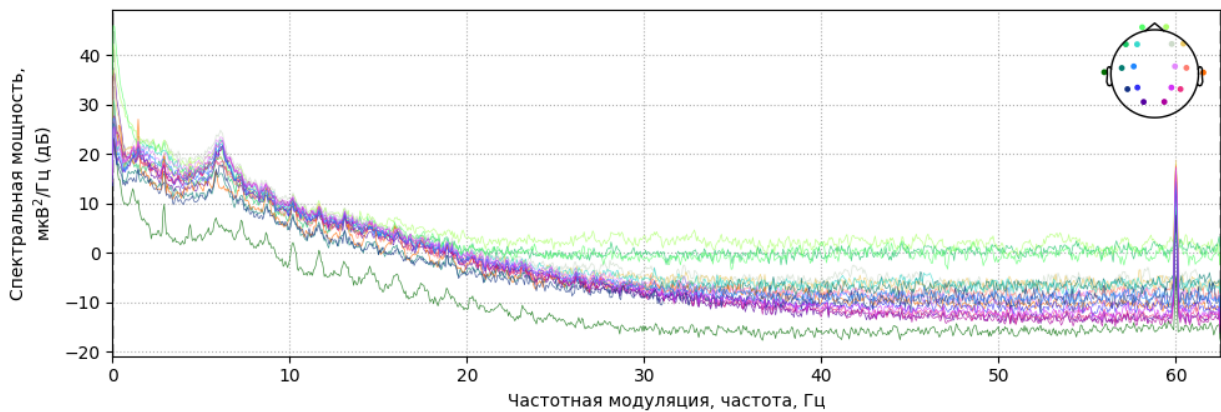


Рисунок 1.3 – Спектральная плотность мощности многоканального сигнала ЭЭГ

Выделяются два основных протокола записи ЭЭГ: 1) ЭЭГ записывается в состоянии покоя с открытыми (Eyes Open, EO) или с закрытыми глазами (Eyes Closed, EC); 2) запись ЭЭГ проводится одновременно с некоторой сенсорной стимуляцией (например, фотостимуляция или гипервентиляция), для усреднения и выявления вызванных потенциалов в ответ на стимул в устойчивом состоянии или во время выполнения когнитивных задач [38].

В исследованиях ЭЭГ используется Международная система 10–20 (Рисунок 1.4) - метод относительного расположения электродов на голове с использованием костных анатомических ориентиров для определения расположения электродов [39, 40]. В современных нейрогарнитурах количество электродов варьируется от 2 до 128 (чаще всего используется 19).




Рисунок 1.4 – Международная система 10–20

ЭЭГ приобретает все большее значение в науке благодаря своей способности давать представление о функции и дисфункции мозга, наблюдается устойчивый тренд роста числа публикаций об ЭЭГ, как показано на Рисунке 1.5. Одной из причин все более широкого использования ЭЭГ является то, что достижения в области обработки сигналов и машинного обучения позволили исследователям извлекать больше информации из данных ЭЭГ.




Рисунок 1.5 – Число публикаций на тему ЭЭГ

1.2 Использование данных электроэнцефалограммы в задачах машинного обучения

Сигналы ЭЭГ содержат значительное количество информации в пространственном, временном и спектральном аспектах. Однако информационная насыщенность ЭЭГ несет не только преимущества, но и недостатки – данные могут иметь высокую размерность и низкое соотношение сигнал/шум, что создает значительные трудности при обработке ЭЭГ и исследовании особенностей (паттернов) мозговой активности. Из-за этих проблем, вручную, аналитически обрабатывать и выделять упомянутые паттерны зачастую маловозможно, поэтому для этих целей применяются методы машинного обучения [41-43].

Большая часть исследований на тему ЭЭГ и машинного обучения посвящена разработке интерфейсов мозг-компьютер (Brain-Computer interface, BCI). BCI — это системы, обеспечивающие прямую связь между мозгом и внешними устройствами, такими как компьютеры или протезы конечностей. Системы BCI имеют особое значение для людей с тяжелой инвалидностью, позволяя им управлять своими протезами [44-48]. В системах BCI на основе машинного обучения использовался разнообразный набор методов извлечения признаков, включая Common Spatial Pattern (CSP) [45, 49], коэффициенты вейвлет-преобразования [50], спектральные признаки [51], сверточные нейронные сети [52] и автокодировщик (AutoEncoder) [53]. Среди моделей машинного обучения, для решения классификации задач моторного воображения использовался ряд классификаторов, таких как Linear Discriminant Analysis (LDA) [54], Support Vector Machine (SVM) [55], k -Nearest Neighbors (k NN) [57], ансамблевый классификатор [56], наивный Байесовский классификатор [57] и глубокие нейронные сети [58].

Детектор P300 – одна из парадигм BCI [59]. Для определения интересующей буквы в парадигме P300-детектора использовалось несколько классификаторов, таких как LDA [60], SVM [61], глубокие нейронные сети (Deep Neural Network, DNN) [62], ансамблевый классификатор [63] и случайный лес (Random Forest, RF) [64]. Существуют и другие парадигмы BCI, такие как устойчивый зрительный

вызванный потенциал (Steady State Visual Evoked Potentials, SSVEP), слуховой, зрительный и гибридный [44]. Эти парадигмы также стали предметом многочисленных исследований (например, [66-68]).

Также ЭЭГ и машинное обучение могут использоваться для детекции микросна. Микросон — это короткие (<15 с) эпизоды непреднамеренной потери сознания, связанной со сном [69]. Микросон может привести к серьезным травмам и смертельному исходу, если он возникает во время выполнения определенных задач, например вождения автомобиля. [70]. Поэтому обнаружение и прогнозирование микросна имеет большое значение для профессий, требующих длительной бесперебойной работы визомоторики. Таким образом, прогнозирование и предварительное предупреждение микросна может предотвратить несчастные случаи и спасти жизни. В [71] изучалось обнаружение микросна по сигналам ЭЭГ [71]. Предсказание надвигающегося микросна также было предметом исследований в [72-74].

Помимо детекции факта наличия самого сна, существует возможность классификации стадий сна. Традиционные методы оценки стадий сна предполагают ручную оценку экспертами, что отнимает много времени. Алгоритмы машинного обучения, такие как SVM и искусственные нейронные сети (ИНС), использовались для классификации стадий сна на основе сигналов ЭЭГ [75]. Также для достижения высокой точности классификации применяются подходы глубокого обучения, такие как свёрточные нейронные сети (Convolutional Neural Net, CNN) и рекуррентные нейросетей с долгой краткосрочной памятью (Long Short-Term Memory, LSTM) [76].

Еще одно применение ЭЭГ и машинного обучения - обнаружение эпилепсии. Алгоритмы извлечения характеристик и классификации, такие как вейвлет-преобразование и SVM, использовались для обнаружения эпилептических припадков по сигналам ЭЭГ [77, 78]. ЭЭГ может использоваться для оценки различных когнитивных функций, таких как внимание, память и восприятие языка. Например, исследователи использовали SVM для классификации состояний

внимания на основе сигналов ЭЭГ [79]. Кроме того, подходы глубокого обучения, такие как CNN, применялись для декодирования нейронной активности, связанной с памятью [79]. Для диагностики болезни Альцгеймера и дифференциации ее от других форм деменции были разработаны модели машинного обучения на основе ЭЭГ [80].

Еще одна сфера применения – так называемый нейрофидбэк (neurofeedback, биологическая обратная связь, БОС). Обучение с помощью нейрофидбэка предполагает использование данных ЭЭГ в реальном времени для получения обратной связи об активности мозга, что позволяет людям научиться регулировать активность мозга в терапевтических целях или при лечении таких заболеваний, как синдром дефицита внимания с гиперактивностью и посттравматическое стрессовое расстройство [81]. Данные ЭЭГ также могут быть использованы для классификации эмоциональных состояний с помощью методов машинного обучения [82].

Таким образом, машинное обучение на основе данных ЭЭГ может применяться для решения широкого спектра задач.

1.3 Методы обработки данных электроэнцефалограммы и извлечения признаков

Устоявшейся практикой [83] является понижение частоты дискретизации сигнала (downsampling), например, понижают частоты дискретизации с 256 Гц до 64 Гц. Это позволяет сэкономить вычислительные ресурсы и снизить время обработки сигнала. Также необработанные данные ЭЭГ содержат помехи (артефакты), которые делятся на два типа: физиологические (связанные с пациентом) и систематические артефакты. Движения тела, дыхание, моргание глаз, потоотделение вызывают физиологические артефакты. Систематические помехи возникают из-за наводок электропитания 50/60 Гц, электрических шумов оборудования, колебаний импеданса электродов или дефектов кабеля. Удаление подобных артефактов и помех зачастую положительно сказывается на качестве

классификации и диагностики на основе данных ЭЭГ. Для этого сигналы ЭЭГ обрабатываются с помощью фильтров низких частот, высоких частот и полосовых фильтров. Фильтры высоких частот (High-pass filter, частота среза ниже 0,5 Гц) позволяют избежать помех очень низкой частоты, например дыхания. Фильтры низких частот (Low-pass filter, частота среза примерно 50–70 Гц) применяются для устранения высокочастотных шумов, а полосовые-заграждающие фильтры (Notch filter, на частоте 50/60 Гц) позволяют устранить наводки электропитания. После предварительной обработки и очистки сигнала ЭЭГ от шума и внешних помех его можно окончательно обработать для извлечения признаков для последующей классификации. Для обработки сигналов ЭЭГ и устранения шумов также применяются другие методы, которые включают в себя регрессионные методы [84, 85], частотную фильтрацию [86], адаптивную фильтрацию [87], фильтрацию Винера [88], методы слепого разделения источников (Blind Source Separation), среди которых Independent Component Analysis, ICA – метод анализа независимых компонент, а также Principal Component Analysis – метод анализа главных компонент) [89, 90]. Также для обработки сигнала применяются вейвлет-преобразования [91].

Помимо перечисленных методов существуют их гибридные версии и множество других аналогов, например, преобразование Фурье, эмпирическое модовое разложение, преобразование Гильберта-Хуанга, преобразование Холо-Гильберта [92, 93]. В [94] для удаления артефактов из набора данных ЭЭГ используется ICA. Затем набор данных ЭЭГ сегментируется на фиксированные временные окна по 50 секунд и фильтруется для удаления шума и помех с использованием эллиптического полосового фильтра. Разбиение на временные окна (эпохи) с небольшим пересечением либо без пересечения (Рисунок 1.6)

обычно применяется для искусственного увеличения объема данных (так называемая аугментация или обогащение данных).

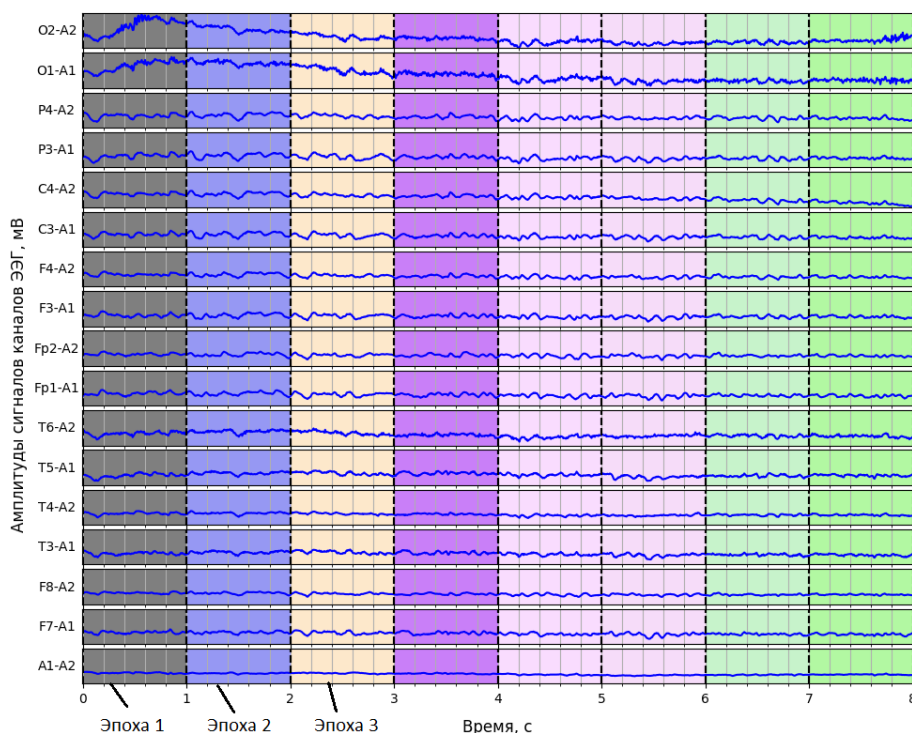


Рисунок 1.6 – Разбиение данных на эпохи без пересечения

Признак можно определить как уникальную характеристику, которая позволяет понять нейронную активность и оценить состояние мозга. Признаки временной области извлекаются непосредственно из необработанных сигналов ЭЭГ. Эти признаки включают среднее значение, дисперсию, асимметрию, эксцесс и морфологию формы волны. Среднее значение и дисперсия являются наиболее часто используемыми признаками временной области. Среднее значение представляет собой среднюю амплитуду сигнала ЭЭГ, а дисперсия - разброс значений амплитуд сигнала относительно математического ожидания. Асимметрия и эксцесс используются для измерения асимметрии и пикообразности сигнала, соответственно. Морфологические признаки формы волны включают расстояние между пиковыми значениями амплитуд, скорость пересечения нуля и другие [95].

Признаки частотной области извлекаются путем преобразования сигналов ЭЭГ из временной области в частотную с помощью преобразования Фурье. Эти характеристики включают спектральную плотность мощности (Power Spectral Density, PSD), спектральную энтропию и когерентность. PSD представляет собой

распределение мощности по различным частотным диапазонам. Спектральная энтропия измеряет неопределенность сигнала в частотной области. Когерентность измеряет степень синхронизации между двумя сигналами ЭЭГ [96].

Частотно-временные признаки извлекаются путем анализа сигналов ЭЭГ во временной и частотной областях. К таким признакам относятся вейвлет-преобразование, оконное преобразование Фурье (Short Time Fourier Transform, STFT) и преобразование Гильберта-Хуанга (ННТ) [97]. Вейвлет-преобразование разлагает сигнал ЭЭГ на различные частотные диапазоны в разные временные интервалы. STFT анализирует сигнал ЭЭГ в коротких временных окнах и вычисляет частотный спектр каждого окна. ННТ разлагает сигнал ЭЭГ на собственные модовые функции (Intrinsic Mode Function, IMF) и извлекает мгновенную частоту и амплитуду каждой IMF:

$$Signal = IMF_1 + IMF_2 + \dots + IMF_i + \dots + IMF_n + Residue, \quad (1.1)$$

где *Signal* – исходный сигнал, *IMF_i* – *i*-я собственная модовая функция, *Residue* – трендовая компонента.

Пространственные признаки извлекаются путем анализа сигналов ЭЭГ, записанных с различных электродов. Эти признаки могут включать в себя топографические карты, дипольное моделирование и ICA. Топографические карты представляют собой распределение активности ЭЭГ по различным электродам. Дипольное моделирование оценивает расположение и ориентацию источников ЭЭГ-активности в мозге. ICA разделяет сигналы ЭЭГ на независимые компоненты, каждая из которых представляет различные источники активности.

Подводя итог, можно выделить два перспективных метода извлечения признаков, которые пока не были использованы для решения задачи верификации субъекта на основе данных ЭЭГ - преобразование Гильберта-Хуанга и преобразование Холо-Гильберта. По результатам использования этих методов на сейсмических данных [98], эти преобразования более эффективно учитывают нестационарность сигнала и нелинейные внутримодовые взаимодействия, что

потенциально может повысить точность систем верификации субъекта на основе данных ЭЭГ.

1.4 Верификация субъекта на основе ЭЭГ

Традиционно в информационных системах используются классические схемы верификации, основанные на учетных данных, состоящих из секретной информации (например, паролей) и/или хранимых токенов (сертификатов, смарт-карт). Пользователь получает доступ к системе после ввода пароля или предъявления токена, чтобы подтвердить свою личность [99]. Для безопасности парольной верификации к паролям предъявляются требования по длине, а также по использованию набора символов и регистра. В итоге пользователям неудобно создавать и запоминать надежные пароли. Также парольная верификация не может работать в пассивном режиме, без отвлечения внимания субъекта.

Альтернатива парольной верификации – верификация на основе уникальных биологических характеристик человека. Среди таких биологических характеристик часто используются отпечаток пальца, ладони, радужка глаза, голос, лицо, рисунок подписи [100, 101]. Для практического использования биологические характеристики должны быть универсальными, стойкими и легко измеряемыми, дающими возможность распознавать субъекта с достаточной для практического применения точностью и достаточно легко вычисляться оборудованием [102]. Основное преимущество верификации на основе физиологических или поведенческих характеристик – удобство для пользователя. В современных смартфонах используются системы распознавания отпечатков пальцев и лиц, которые позволяют довольно быстро распознать субъекта. Еще одно преимущество подобных систем верификации – требование физического присутствия субъекта.

Одно из преимуществ системы на основе ЭЭГ это мультифункциональность – можно использовать данные одновременно не только для верификации субъекта, но и для других целей, например, для распознавания эмоций, изучения сна и здоровья. В [103] описано создание новой автоматизированной системы

стадирования сна, основанной на модели стекирования ансамблевого обучения, которая объединяет алгоритм RF и экстремальный градиентный бустинг (Extreme Gradient Boosting, XGBoosting), достигая точность равную 90,56%. В работе [104] использованы данные ЭЭГ от 6 каналов для выявления пациентов с инсультом с помощью дерева решений, построенного алгоритмом C5.0 и достигшего точности 89,00%. Данные ЭЭГ также могут быть использованы для классификации болезни Паркинсона (БП), авторы работы [105] использовали дискриминантный функциональный анализ (FDA) и достигли точности 62,00% только по данным ЭЭГ и точности 98,80% при сочетании ЭЭГ и данных электромиограммы. В работе [106] классификация пациентов для диагностики БП была выполнена с использованием 13-слойной нейронной сети и достигла точности 88,20%.

Среди недостатков сигнала ЭЭГ стоит отметить возможность подделки или компрометации сигналов ЭЭГ, например в [107] исследована атака на систему верификации на основе ЭЭГ с использованием генеративно-сопоставительных сетей (Generative adversarial network, GAN) и изучены меры повышения устойчивости к подобным атакам. Одна из особенностей сигнала ЭЭГ заключается в том, что данные ЭЭГ могут меняться в зависимости от состояния и эмоций субъекта [108, 109], что может негативно сказаться на устойчивости работы (робастности) систем верификации на их основе. Сверточная нейронная сеть с динамическим графом в [110], RF в [103, 111], k NN в [82] позволяют классифицировать эмоции по данным ЭЭГ с точностью более 80 %.

Первым исследованием на тему распознавания субъектов на основе электроэнцефалограммы с помощью методов машинного обучения была система Пирейского университета 1999 года [113]. В данной работе использовалась сеть векторного квантователя с точностью от 72% до 84%. В работе исследовалась возможность использования мобильной версии системы - интерфейса индивидуальной верификации на основе ЭЭГ в реальном времени для повсеместных приложений. Сигналы ЭЭГ собирались по единственному

монополярному каналу в реальном времени с помощью мобильного устройства ЭЭГ.

В другом исследовании [114] использовались методы k NN и LDA. В эксперименте участвовало 20 человек. В данной работе участникам предлагалось выполнять задания во время съема сигнала: движение рукой или воображаемое движение рукой. Точность составила от 94,75% до 98,03% правильной классификации. В [115] использовалась двухслойная CNN, для эксперимента было набрано 30 человек. Во время первого сеанса снятия сигнала участников просили представлять свое лицо, во время второго участников попросили моргнуть 10–12 раз. Точность такого подхода составила 97,60% правильной классификации. В [116] использовался PhysioNet “EEG Motor Movement/Imagery Dataset” (PEEGMMID) [117] из общедоступного банка данных PhysioNet [118]. 109 испытуемых участвовали в выполнении заданий на представление движений. 64-канальная ЭЭГ была записана с помощью VCI2000. Исследователи провели сравнение 3 различных канальных наборов: 8 каналов, 16 каналов и 64 канала. Для всех систем точность была выше 85% (максимальная точность достигнута для 64 каналов - 95,64%).

В статье [119] было выявлено, что сигнал одних людей может сильно измениться со временем, в то время как других практически нет. В [120, 121] также использовался PhysioNet, однако авторы обеих работ использовали только часть каналов. Работа [122] демонстрирует увеличение точности (99,80%) за счет изменения процедуры предобработки данных. Для уменьшения размерности используются PCA и LDA. В качестве классификатора использовался k NN. В статье [123] рассматривается обучение на данных, собранных в течение пяти сеансов за полтора года. Такой подход позволяет обнаружить признаки, устойчивые в течение продолжительного времени. Существуют также работы, в которых одновременно снимается сигнал ЭЭГ и ручная подпись. Например, в работе [124] удалось получить точность 98,57%, использовав модель multimodal Siamese Neural Network. Статья [125] рассматривает способы сделать верификацию

более удобной для субъекта. Использовались устройства потребительского уровня, а сам процесс записи не занимал много времени. Для классификации использовалась SVM, точность результатов составила 83,70–96,42%.

Согласно обзору систем верификации на основе ЭЭГ [127], для снятия данных используется стандартная схема отведений (10–20). Для снятия данных используется состояние покоя (~33% исследований) или снятие проводится при наличии внешних визуальных стимулов. Все большее распространение получают устройства снятия ЭЭГ, работающие по протоколу Bluetooth, с уменьшенным числом “сухих” отведений (для лучшей проводимости могут использоваться влажные электроды).

Для систем верификации на основе ЭЭГ выделяются следующие основные проблемы:

1) используемые наборы данных в недостаточной степени разнообразны и сбалансированы по составу субъектов (по возрасту, полу, здоровью, наличию или отсутствию вредных привычек);

2) построенные модели тренируются, в основном, на predeterminedную группу субъектов для работы в режиме “один-ко-многим”, моделей для работы в режиме “один-к-одному” достаточно мало;

3) ЭЭГ - нестационарный сигнал, большая часть наборов данных и исследований не учитывает возможность изменения сигнала в течение длительного промежутка времени и возможную деградацию точности моделей верификации. Существующие наборы данных в публичном доступе включают только одну сессию снятия данных, мультисессионные наборы данных в открытом доступе отсутствуют;

4) используемые модели, особенно модели глубокого обучения, зачастую мало интерпретируемы или объясняемы.

Из публично доступных наборов данных большинство исследований верификации на основе ЭЭГ используют набор данных REEGMMID (Таблица 1.2, Таблица 1.3). Основная проблема данных работ заключается в том, что не

использовался протокол разделения данных, который исключает данные части субъектов полностью из обучающей выборки. Вместо этого часть сегментов данных субъекта попадала в обучающую выборку (Рисунок 1.7), за счет чего полноценно не оценивалась работа модели на данных неизвестных ей субъектов. Использование протокола полного исключения данных тестовых субъектов из обучающей выборки может привести к значительному снижению точности и более полно соответствовать реальным условиям для оценки эффективности работы модели, что и будет показано в дальнейшем в этой работе.

Таблица 1.2 - Работы по верификации на основе ЭЭГ

Статья	Набор данных	Число субъектов; число каналов	Длина сегмента	Точность (%)
[116]	PEEGMMID	109; 64	2,00 с	95,64
[128]	PEEGMMID	108; 56	10,00 с	100,00
[126]	Публично недоступен	50; 7	5,00 с	90,00
[129]	Публично недоступен	50; 19	5,00 с	88,00
[130]	Публично недоступен	30; 19	5,00 с	71,00
[131]	PEEGMMID	109; 1	12,00 с	97,00
[132]	PEEGMMID	109; 64	1,00 с	98,83
[133]	Публично недоступен	100; 64	1,00 с	97,00
[134]	PEEGMMID	109; 16	1,00 с	99,58
[134]	PEEGMMID	109; 4	1,00 с	94,28
[135]	PEEGMMID	109; 64	5,50 с	99,98
[135]	Публично недоступен	59; 46	5,50 с	98,96
[136]	PEEGMMID	109; 64	1,00 с	99,78
[138]	PEEGMMID	109; 3	1,00 с	98,04
[141]	PEEGMMID	109; 2	5,00 с	99,05

Таблица 1.3 - Работы по верификации на основе ЭЭГ

Статья	Набор данных	Число субъектов; число каналов	Длина сегмента	EER (%)
[138]	Публично недоступен	50; 17	0,60 с	8,00
[139]	PEEGMMID	109; 10	7,50 с	0,02
[140]	PEEGMMID	109; 64	12,00 с	0,19
[134]	PEEGMMID	109; 16	1,00 с	0,41
[134]	PEEGMMID	109; 4	1,00 с	0,56
[141]	PEEGMMID	109; 2	5,00 с	0,19




Рисунок 1.7 – Разделение данных из [141]

1.5 Интерпретируемые методы и модели машинного обучения

Сложность моделей машинного обучения часто приводит к отсутствию прозрачности и интерпретируемости, что вызывает опасения по поводу их достоверности и этических последствий, низкую степень доверия со стороны человека. Объяснимое машинное обучение направлено на решение этих проблем путем разработки моделей и методов, которые предоставляют понятные человеку объяснения своих прогнозов и решений.

Линейные модели, такие как линейная регрессия и логистическая регрессия, по своей сути интерпретируемы благодаря простой математической структуре. Они моделируют связь между входными признаками и выходными прогнозами с помощью линейной комбинации весов признаков. Веса можно напрямую интерпретировать как важность каждого признака в процессе принятия решений в модели. Например, в работе [142] используется линейная регрессионная модель для распознавания движения конечностей. К сожалению, емкости линейных моделей зачастую не хватает достижения приемлемой точности или работы с нелинейными зависимостями [143].

Деревья решений — это еще один класс интерпретируемых моделей, которые рекурсивно разбивают входное пространство на области на основе

значений признаков. Каждый внутренний узел дерева представляет собой правило принятия решения, а листовые конечные узлы - итоговые прогнозы. Деревья решений легко визуализируются и могут быть понятны неспециалистам, что делает их популярным выбором для объясняемых моделей. Деревья решений широко применяются в задачах классификации на основе сигнала ЭЭГ, например – в работе [159]. Недостатком деревьев решений и ансамблей на основе деревьев решений зачастую является избыточная сложность структуры, что сводит на нет возможность интерпретации подобных моделей (Рисунок 1.8, Рисунок 1.9).

Модели на основе правил, такие как, например, нечеткие классификаторы, представляют собой коллекции правил "ЕСЛИ–ТО", которые описывают связь между входными характеристиками и выходными прогнозами. Эти модели хорошо поддаются интерпретации, если правил достаточно мало, поскольку каждое правило может быть непосредственно сопоставлено с понятным человеку объяснением.

Модель-агностические методы нацелены на предоставление объяснений для любой модели машинного обучения, рассматривая модель как "черный ящик". К популярным методам такого вида относятся LIME (Local Interpretable Model-agnostic Explanations) и SHAP. В [144] используется метод LIME для выделения наиболее важных признаков в задаче распознавания эмоций по сигналу ЭЭГ. В работе [145] решается задача классификации двух состояний на основе ЭЭГ, когда человек касается экрана и не касается. С помощью значений SHAP были выявлены наиболее важные для поставленной задачи классификации каналы ЭЭГ. Методы специфичные для конкретной модели используют их внутреннюю структуру для получения объяснений. Например, Байесовские модели обеспечивают вероятностную основу для рассуждений о неопределенности. Методы объяснения байесовских моделей используют апостериорное распределение параметров

модели для количественной оценки неопределенности и важности характеристик в процессе принятия решений в модели.




Рисунок 1.8 – Избыточная сложность структуры дерева решений

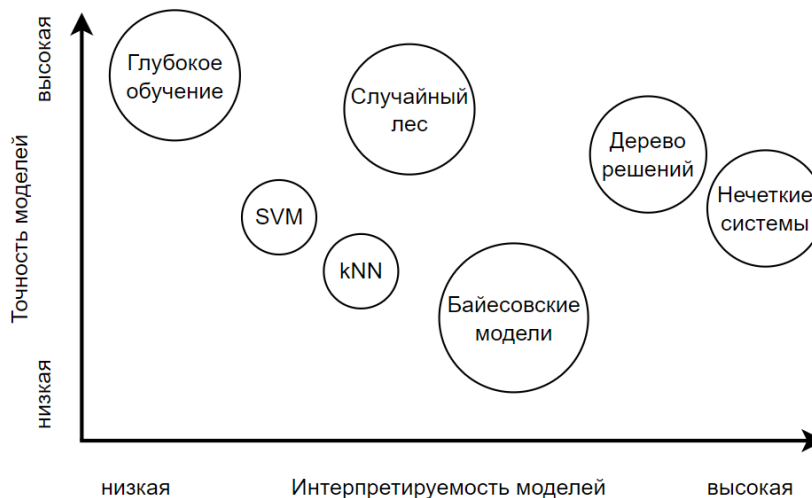


Рисунок 1.9 – Условное сравнение точности и интерпретируемости для основных моделей машинного обучения

Модели глубокого обучения считаются "черными ящиками" (black-box) из-за их сложной архитектуры и невозможности прямой интерпретации. Одним из методов объяснения вывода подобных моделей является определение областей входных данных, которые вносят наибольший вклад в конечный результат модели. Однако существующие подходы имеют ряд недостатков: плохая чувствительность

и неустойчивость к конкретной реализации модели. В [146] авторы базируются на двух аксиомах: чувствительности и инвариантности реализации, предложив метод атрибуции Integrated Gradients, который разработан на основе этих двух аксиом.

Таким образом, можно подвести итог, что проблема интерпретируемости особенно актуальна в контексте применения методов машинного обучения для ЭЭГ сигнала. Интерпретируемость и объяснимость моделей важна как для медицинского применения, так и для сферы безопасности и контроля доступа – важно обеспечить доверие персонала к моделям через понимание того, как эти модели работают и принимают решения. Наилучшим вариантом могут быть системы на основе правил или дерева решений, но точность системы может пострадать в угоду интерпретируемости, если число правил будет низким или структура дерева слишком простой. Подходы на основе глубокого обучения могут обеспечить более высокую точность, но изначально не интерпретируемы. Существуют методы, которые могут оценить лишь важность каждого входного признака для выходного результата, но не более.

1.6 Нечеткие классификаторы

Нечеткие системы основаны на теории нечетких множеств, которая была введена Лотфи А. Заде в 1965 году [21] как расширение классической теории множеств. Работа Заде была ответом на ограничения классической теории множеств и двоичной логики, которые не могли эффективно моделировать и обрабатывать неопределенную и неточную информацию. Теория нечетких множеств обеспечила более гибкую и надежную основу для работы с такой информацией, проложив путь к развитию нечетких систем. Нечеткие классификаторы основаны на правилах вида “ЕСЛИ-ТО”, за счет чего являются гибкими, функциональными, интерпретируемыми, могут быть построены на основе знаний эксперта.

В процессе построения нечетких классификаторов решаются задачи отбора признаков, генерации базы нечетких правил, оптимизация параметров правил. Отбор признаков при решении задач классификации направлен на снижение

размерности исходного признакового пространства данных и снижение информационной избыточности, что позволяет ускорить процесс обучения классификатора и избежать переобучения. Для генерации базы нечетких правил чаще всего используются алгоритмы кластеризации, в результате формируется начальное, «грубое» приближение нечеткого классификатора [147]. Алгоритм автономного разделения данных (Autonomous Data Partitioning, ADP) [148] - полностью автономный алгоритм разбиения данных на локальные моды, который способен автоматически распознавать локальные максимумы плотности данных из эмпирических наблюдений и использовать их в качестве фокальных точек для формирования бесформенных "облаков" данных, представляющих собой разновидность тесселяции Вороного. Данный алгоритм ранее не применялся для генерации структуры нечетких систем и потенциально может повысить точность нечетких классификаторов, построенных с его помощью.

Процедура оптимизации нечеткого классификатора может выполняться с помощью метаэвристических алгоритмов. Метаэвристические алгоритмы — это класс алгоритмов оптимизации, которые используются для решения сложных задач, которые трудно или невозможно решить с помощью традиционных методов оптимизации. Эти алгоритмы вдохновлены естественными процессами, такими как эволюция, поведение роя и естественный отбор, и предназначены для эффективного и результативного исследования больших пространств поиска. Алгоритм “стаи птиц” (Bird Swarm Algorithm, BSA) [149] основан на результатах наблюдений за поведением птиц, которым свойственно объединение в стаи и общение между собой с помощью разнообразных звуковых сигналов. Алгоритм нашел применение в задачах оптимизации параметров пропорционально-интегрально-дифференцирующих регуляторов [150], планирования задач при осуществлении облачных вычислений [151], разделения сигналов одинаковой частоты для преодоления влияния помех на корабельные радары [152]. Подводя итог, возможность использования метаэвристического алгоритма BSA именно для

оптимизации параметров нечеткого классификатора для верификации на основе данных ЭЭГ не изучена и является перспективным направлением исследования.

Отбор признаков - важнейший этап машинного обучения, поскольку он помогает определить наиболее значимые признаки, которые способствуют прогнозированию целевой переменной. В случае сигнала ЭЭГ пространство признаков имеет особенно высокую размерность на счет использования большого количества датчиков (каналов) снятия данных, в отдельных случаях их может быть более 100 и число признаков кратно возрастает [27]. Многие исследования систем ВСІ также показали, что объединение нескольких типов признаков (например, объединение временных и частотных признаков) увеличивает точность классификации, но еще больше увеличивает размерность. Методы понижения и отбора признаков в данном контексте становятся особенно важны, выбор наиболее релевантных признаков необходим для снижения вычислительных затрат, возникающих из-за размерности. Для решения этой проблемы в работах [153-155] были использованы анализ главных компонент, ReliefF, минимальная избыточность максимальной релевантности (minimum redundancy maximum relevance, mRMR) и рекурсивное исключение признаков (Recursive Feature Elimination, RFE) для пяти различных классификаторов сигналов ЭЭГ, а именно глубокой нейронной сети DNN, SVM, k -NN, линейного дискриминантного анализа и случайного леса. В отдельных работах [156, 157] проводится отбор не отдельных признаков, а каналов данных ЭЭГ, наиболее значимых для поставленной задачи классификации, в том числе и с применением метаэвристических алгоритмов.

Методы отбора признаков подразделяются на методы фильтрации, оберточные, встроенные методы. Обособленно выделяются такие методы снижения размерности, как PCA или LDA, которые уменьшают размерность данных, проецируя их на более низкоразмерное пространство. Методы фильтрации являются наиболее простыми и популярными методами. Новые признаки являются линейной комбинацией исходных признаков и выбираются на основе их вклада в дисперсию или дискриминацию данных. Методы снижения размерности

эффективны с вычислительной точки зрения и могут работать с большими наборами данных. Однако они могут не сохранять интерпретируемость исходных признаков и не подходить для нелинейных отношений. Оберточные методы более сложны, чем методы фильтрации, и предполагают обучение модели на различных подмножествах признаков. Затем оценивается производительность модели, и выбираются признаки, которые вносят наибольший вклад в производительность модели. Методы обертки требуют больших вычислительных затрат, однако они учитывают взаимодействие между признаками и могут учитывать нелинейные связи между признаками. Учесть взаимодействие между признаками потенциально можно при помощи бинаризованных метаэвристик. Алгоритм “стаи птиц” можно использовать в разных задачах, как и для оптимизации параметров нечеткой системы, так и для отбора признаков, повысив точность итоговой системы, что будет показано в ходе работы.

Единственное упоминание применения нечеткого классификатора при работе с данными ЭЭГ в работе [148], где используется нечеткий Takagi-Sugeno-Kang (TSK) классификатор для определения эпилептических приступов. Таким образом, применение заведомо интерпретируемого нечеткого классификатора является перспективным и малоизученным направлением исследований.

В данной работе рассматриваются нечеткие классификаторы типа синглтон. Нечеткие классификаторы типа синглтон состоят из базы продукционных правил, оценивающих входной признаковый вектор $\mathbf{x} = (x_1, x_2, \dots, x_n)$ нечеткими термами следующего вида:

$$R_j: \text{ЕСЛИ } s_1 \wedge x_1 = T_{1j}, \text{ И } s_2 \wedge x_2 = T_{2j}, \text{ И } \dots, \text{ И } s_n \wedge x_n = T_{nj}, \text{ ТО class} = c_j, \quad (1.2)$$

где T_{ij} – нечеткое множество (лингвистический терм), характеризующее i -ый признак в правиле R_j , $j = 1, \dots, R$, R – количество правил; c_j – индекс класса j -го правила, $\mathbf{S} = (s_1, s_2, \dots, s_n)$, где $s_i = 0$ означает, что i -й признак не участвует в классификации, $s_i = 1$ означает, что i -й признак используется классификатором.

Цель отбора признаков состоит в поиске оптимального вектора признаков \mathbf{S} , который хранит информацию об использовании, либо игнорировании признака

нечетким классификатором. Для найденных вариантов вектора признаков \mathbf{S} оценивается точность классификации. Использование вектора признаков \mathbf{S} не должно существенно снижать точность классификации. В случае генерации базы правил кластеризацией каждое правило нечеткой системы представляет собой прототип кластера, характеризующегося средним значением (центроидом) и разбросом значений относительно среднего.

Процесс нечеткого вывода для входного вектора \mathbf{x}_p (классификации вектора), выполняется следующим образом:

1) вычисление степени принадлежности вектора \mathbf{x}_p к перечню термов каждого правила. Для j -го правила степень принадлежности $\mu_j(\mathbf{x}_p, \boldsymbol{\theta}_j, \mathbf{S})$ определяется формулой, представленной ниже:

$$\mu_j(\mathbf{x}_p, \boldsymbol{\theta}_j, \mathbf{S}) = \prod_{i=1}^n \mu(x_{pi}, \boldsymbol{\theta}_{ij}, s_i), \quad (1.3)$$

где μ – функция принадлежности признака x_{pi} нечеткому терму T_{ij} ; $\boldsymbol{\theta}_{ij}$ – параметры функции принадлежности, задающего нечеткий терм T_{ij} , $\boldsymbol{\theta}_j = [\boldsymbol{\theta}_{1j}, \dots, \boldsymbol{\theta}_{ij}, \dots, \boldsymbol{\theta}_{nj}]$. Наиболее часто для нечетких систем используется треугольная, трапецевидная и гауссова функции принадлежности. В данной работе используется гауссова функция принадлежности, задаваемая следующим образом:

$$\mu(x_{pi}, \boldsymbol{\theta}_{ij}, s_i) = \exp\left(-\left(\frac{x_i - a_i}{b_i}\right)^2\right), \quad (1.4)$$

где $\boldsymbol{\theta}_{ij} = [a_{ij}, b_{ij}]$.

2) вычисление степени принадлежности входного вектора \mathbf{x} каждому имеющемуся классу. Для k -го класса ($k=1, \dots, M$, M – число классов) степень уверенности $\beta_k(\mathbf{x})$ рассчитывается следующим образом:

$$\beta_k(\mathbf{x}_{pi}, \boldsymbol{\theta}, \mathbf{S}) = \sum_{j|c_j=k} \mu(\mathbf{x}_{pi}, \boldsymbol{\theta}, \mathbf{S}), \quad (1.5)$$

где $\boldsymbol{\theta}$ – вектор с параметрами антецедентов (параметрами термов, задающих соответствующие функции принадлежности в ЕСЛИ-части правил).

3) для \mathbf{x} определяется класс с максимальной уверенностью в принадлежности:

$$\text{class}(\mathbf{x}_p, \boldsymbol{\theta}, \mathbf{S}) = \arg \max_{k=1, \dots, M} \{\beta_k(\mathbf{x}_{pi}, \boldsymbol{\theta}, \mathbf{S})\}. \quad (1.6)$$

Для обучения нечеткого классификатора необходимо разбиение набора данных на две выборки – обучающую *Train* и тестовую *Test*:

$$\text{Train} = \{(\mathbf{x}_i, c_i)\} \mid c_i \in \{1, \dots, M\}, i = 1, \dots, |\text{Train}|, \quad (1.7)$$

$$\text{Test} = \{(\mathbf{x}_i, c_i)\} \mid c_i \in \{1, \dots, M\}, i = 1, \dots, |\text{Test}|, \quad (1.8)$$

где $\text{Train} \cap \text{Test} = \emptyset, |X| = |\text{Train}| + |\text{Test}|, |\mathbf{x}_i| = n$.

Оценка точности классификатора (фитнесс-функция) вычисляется как доля правильной классификации $E(\text{data}, \boldsymbol{\theta}, \mathbf{S})$:

$$\text{delta}(\text{data}_p, \boldsymbol{\theta}, \mathbf{S}) = \begin{cases} 1, & \text{если } c_p = \text{class}(\mathbf{x}_p, \boldsymbol{\theta}, \mathbf{S}) \\ 0 & \text{иначе} \end{cases}, \quad (1.9)$$

$$E(\text{data}, \boldsymbol{\theta}, \mathbf{S}) = \frac{\sum_{p=1}^{|\text{data}|} \text{delta}(\text{data}_p, \boldsymbol{\theta}, \mathbf{S})}{|\text{data}|}, \quad (1.10)$$

где data - $|\text{Train}|$ или $|\text{Test}|$, $p = 1, 2, \dots, |\text{data}|, \mathbf{x}_p = \text{data}_p$.

Таким образом, проблема построения нечеткого классификатора сводится к оптимизации \mathbf{S} и $\boldsymbol{\theta}$ для поиска максимума функции $E(\text{data}, \boldsymbol{\theta}, \mathbf{S})$.

1.7 Метрическое обучение

Метрическое обучение – группа методов, целью которых является определение схожести между образцами данных. Для этого, для конечного множества образцов данных \mathcal{X} и соответствующих меток классов \mathcal{Y} необходимо обучить, так называемую, эмбединговую нейронную сеть $\text{Net}_{\boldsymbol{\theta}}(\cdot): \mathcal{X} \rightarrow \mathbb{R}^n$ (в данном случае, $\boldsymbol{\theta}$ – веса обученной эмбединговой нейронной сети). Для обучения также выбирается метрика расстояния $\mathcal{D}: \mathbb{R}^n \rightarrow \mathbb{R}$. Обучение ведется таким образом, чтобы для любых двух образцов данных $x_1, x_2 \in \mathcal{X}$ и их меток класса $y_1, y_2 \in \mathcal{Y}$ метрика $\mathcal{D}(\text{Net}_{\boldsymbol{\theta}}(x_1), \text{Net}_{\boldsymbol{\theta}}(x_2))$ показывает близость образцов, если y_1, y_2 совпадает, либо показывает большое расстояние между объектами, если это образцы разных классов. Таким образом, задача метрического обучения сводится к выбору архитектуры сети $\text{Net}_{\boldsymbol{\theta}}$, функции потерь $\mathcal{L}(\boldsymbol{\theta})$ для обучения сети и получения параметров $\boldsymbol{\theta}$, выбору метрики расстояния \mathcal{D} . В метрическом обучении

используются иные функции потерь, нежели чем обычно используемая кросс-энтропия. Хотя кросс-энтропия применима для метрического обучения, она и уступает другим функциям потерь, например контрастной или триплетной (Рисунок 1.10).




Рисунок 1.10 – Основная идея триплетной функции потерь [160]

Триплетная функция потерь – наиболее популярная функция потерь метрического обучения. Пусть $x_a, x_p, x_n \in \mathcal{X}$, им соответствуют метки классов $y_a, y_p, y_n \in \mathcal{Y}$, $y_a = y_p$, $y_a \neq y_n$. x_a называется якорным примером (Anchor), x_p называется положительным примером (Positive), x_n называется негативным примером (Negative). Вместе, эти примеры формируют триплет. Затем, для пакета (батча) сформированных триплетов вычисляется функция потерь:

$$\mathcal{L}_{trpl} = \frac{1}{m} \sum_{i=1}^m \{ \max(0, s_{ni}^2 - s_{pi}^2 + \alpha) \}, \quad (1.11)$$

$$s_{ni} = \mathcal{D}(Net_{\theta}(x_a^i), Net_{\theta}(x_n^i)), \quad (1.12)$$

$$s_{pi} = \mathcal{D}(Net_{\theta}(x_a^i), Net_{\theta}(x_p^i)), \quad (1.13)$$

где α – отступ, гиперпараметр, который не позволяет отобразить все данные в одну точку; m – число примеров в пакете.

Триплетная функция считает потери по пакету триплетов, который формируется случайным образом из набора всевозможных пар образцов данных из набора, результат усредняется. Для улучшения сходимости, в пакете выбираются только те триплеты, для которых $\mathcal{D}(Net_{\theta}(x_a), Net_{\theta}(x_n)) < \mathcal{D}(Net_{\theta}(x_a), Net_{\theta}(x_p)) + \alpha$. Данная стратегия называется Negative Samples Mining.

Триплетная функция потерь – наиболее простая из функций потерь метрического обучения. В данной работе используется функция потерь Multi-Similarity Loss [160]:

$$\mathcal{L}_{ms} = \frac{1}{m} \sum_{i=1}^m \left\{ \frac{1}{\alpha} [1 + \sum_{k \in \mathcal{P}_i} e^{-\alpha(s_{ik}-\lambda)}] + \frac{1}{\beta} [1 + \sum_{k \in \mathcal{N}_i} e^{\beta(s_{ik}-\lambda)}] \right\}, \quad (1.14)$$

$$s_{ij} = \mathcal{D}(Net_{\theta}(x_i), Net_{\theta}(x_j)), \quad (1.15)$$

где \mathcal{P}_i – множество индексов позитивных примеров для i -го примера в батче, \mathcal{N}_i – множество индексов негативных примеров для i -го примера в батче; α, β – гиперпараметры. Данная функция потерь также учитывает самоподобие, что позволяет увеличить точность и сходимость метрического обучения.

Метрическое обучение успешно используется в архитектуре FaceNet [161], предназначенной для распознавания лиц с достаточно высокой точностью (EER <10,00%). Применение метрического обучения для верификации на основе данных электроэнцефалограммы потенциально может улучшить точность распознавания субъектов вне обучающей выборки.

1.8 Постановка задачи верификации

Пусть многоканальный сегмент сигнала ЭЭГ (эпоха) определяется как:

$$\mathbf{epoch}_i = [\mathbf{epoch}_i^1, \dots, \mathbf{epoch}_i^k, \dots, \mathbf{epoch}_i^{channels}], \quad (1.16)$$

$$\mathbf{epoch}_i^k = [epoch_{i,1}^k, epoch_{i,2}^k, \dots, epoch_{i,j}^k, \dots, epoch_{i,sl}^k], \quad (1.17)$$

где $epoch_{i,j}^k$ – значение амплитуды сигнала ЭЭГ в j -й отсчет времени для k -го канала (*channels* – число каналов), sl – число отсчетов (длина сегмента), $sl = srate * time$, *srate* – частота дискретизации (сэмплинга) в Гц, *time* – длина сегмента в секундах. Запись ЭЭГ, из которых создаются сегменты, определяется как:

$$\mathbf{e} = [\mathbf{epoch}_1, \dots, \mathbf{epoch}_i, \dots, \mathbf{epoch}_{count}] \quad (1.18)$$

где *count* – число эпох, на которые можно разделить запись ЭЭГ (с пересечением или без). Набор данных ЭЭГ с разделением на эпохи можно представить следующим образом:

$$EEG = \{(\mathbf{epoch}_i, c_i) \mid id_i \in [1, \dots, P], i = 1, \dots, |EEG|\} \quad (1.19)$$

где P – число субъектов в наборе данных.

Для оценки точности системы генерируется случайное число пар:

$$EEG_{paired} = \{(\mathbf{epoch}_{i1}, \mathbf{epoch}_{i2}, c_i) \mid c_i \in \{0,1\}; \mathbf{epoch}_{i1}, \mathbf{epoch}_{i2} \in EEG\} \quad (1.20)$$

Эпохи с помощью функции извлечения признаков *Extract* (алгоритма извлечения признаков) преобразуется к следующему виду:

$$\mathbf{f}_i = [f_1, \dots, f_i, \dots, f_n], \quad (1.21)$$

$$\mathbf{f}_i = \text{Extract}(\mathbf{epoch}_i), \quad (1.22)$$

где n – число извлекаемых признаков.

Пусть $(\mathbf{epoch}_{i1}, \mathbf{epoch}_{i2}, c_i)$ подается на вход системе. В случае работы в режиме верификации нечеткой системы *FS* вывод выглядит следующим образом:

$$FS(\mathbf{x}^i, \boldsymbol{\theta}, \mathbf{S}) = id_{class(\mathbf{x}^i, \boldsymbol{\theta}, \mathbf{S})}, id_i \in [0,1], \quad (1.23)$$

$$\beta_k(\mathbf{x}^i) = \sum_{(j|c_j=k)} \mu_j(\mathbf{x}^i, \boldsymbol{\theta}, \mathbf{S}), \quad (1.24)$$

$$class(\mathbf{x}^i, \boldsymbol{\theta}, \mathbf{S}) = \arg \max_{k=1, \dots, M} \{\beta_k(\mathbf{x}^i, \boldsymbol{\theta}, \mathbf{S})\}, \quad (1.25)$$

$$predict(\mathbf{epoch}_{i1}, \mathbf{epoch}_{i2}) = FS(\mathbf{x}^i, \boldsymbol{\theta}, \mathbf{S}), \quad (1.26)$$

где $\mathbf{x}^i = diff(Extract(\mathbf{epoch}_{i1}), Extract(\mathbf{epoch}_{i2}))$, *diff* – функция вычисления поэлементных разностей векторов.

В случае нечеткой системы эффективность модели оценивается по доле правильной классификации:

$$delta(i, \boldsymbol{\theta}, \mathbf{S}) = \begin{cases} 1, & \text{если } predict(\mathbf{epoch}_{i1}, \mathbf{epoch}_{i2}) = c_i, \\ 0, & \text{иначе} \end{cases}, \quad (1.27)$$

$$E(EEG_{paired}, \boldsymbol{\theta}, \mathbf{S}) = \frac{\sum_{p=1}^{|EEG_{paired}|} delta(p, \boldsymbol{\theta}, \mathbf{S})}{|EEG_{paired}|}. \quad (1.28)$$

Пусть $(\mathbf{epoch}_{i1}, \mathbf{epoch}_{i2}, c_i)$ подается на вход системе на основе нейронных сетей и метрического обучения. В случае работы в режиме верификации нейронной сети вывод выглядит следующим образом:

$$\mathbf{x}^i = d(Net_{\theta}(\mathbf{epoch}_{i1}), Net_{\theta}(\mathbf{epoch}_{i2})), \quad (1.29)$$

$$Scores = \{\mathbf{x}^1, \dots, \mathbf{x}^{|EEG_{paired}|}\}, \quad (1.30)$$

$$class = \begin{cases} 1, & \text{если } Scores_i > threshold \\ 0, & \text{иначе} \end{cases}, \quad (1.31)$$

где *threshold* – подобранный порог верификации, значения которого перебираются от 0 до 1 для построения кривой Detection Error Tradeoff (DET), которая используется в современных системах верификации на основе ЭЭГ и не только. Equal Error Rate (EER) — это место на кривой DET, где частота ошибок первого рода (False Negative Rate, TPR) равна частоте ошибок второго рода (False Positive Rate, FPR). В целом, чем ниже значение данного показателя, тем выше точность системы верификации.

В случае метрического обучения и нейронных сетей, задача сводится к выбору архитектуры сети Net_{θ} , метрики расстояния \mathcal{D} , функции потерь $\mathcal{L}(\theta)$ и получения параметров θ при которых метрика EER принимает минимальное значение. Так как в случае нечеткой системы используются поэлементные разности векторов в качестве признаков, эффективность модели оценивается по доле правильной классификации, поэтому проблема построения нечеткого классификатора сводится к оптимизации \mathbf{S} и θ для поиска максимума доли правильной классификации.

1.9 Выводы

1. Среди публично доступных наборов данных ЭЭГ для верификации модели-аналоги в основном обучаются на односессии наборе данных – Physionet. Основная проблема данных работ и моделей заключается в том, что не использовался протокол разделения данных, который исключает данные части субъектов из обучающей выборки полностью. Использование протокола полного исключения данных тестовых субъектов из обучающей выборки может привести к значительному снижению точности и больше подходит для оценки эффективности работы модели. Также, для повышения обобщающей способности модели - способности работать с ранее модели неизвестными субъектами без её

перестроения или снижения точности - необходимо прибегнуть к метрическому обучению.

2. ЭЭГ - нестационарный сигнал, большая часть наборов данных и исследований не учитывает возможность изменения сигнала в течение длительного промежутка времени и возможную деградацию точности моделей верификации. Для учета нестационарности сигнала, для извлечения признаков можно выделить два перспективных метода спектрального анализа, которые пока были не использованы для решения задачи верификации субъекта на основе данных ЭЭГ - преобразование Гильберта-Хуанга и преобразование Холо-Гильберта. По результатам использования этих методов на сейсмических данных [98], эти преобразования более эффективно учитывают нестационарность сигнала и нелинейные модовые взаимодействия, что потенциально может повысить точность систем верификации субъекта на основе данных ЭЭГ.

3. Используемые модели и методы извлечения признаков, особенно модели глубокого обучения, зачастую мало интерпретируемы или объясняемы. Для решения данной проблемы можно использовать интерпретируемые по своей природе нечеткие классификаторы. Построение нечеткого классификатора можно разделить на два этапа: создание базовой структуры и её оптимизация. Для построения структуры нечеткого классификатора можно использовать методы кластеризации на основе метаэвристических алгоритмов, для которых необходимо заранее задать требуемое число правил. Метаэвристические методы кластеризации, по сравнению с классическими методами кластеризации, потенциально могут помочь достичь более приемлемого компромисса между точностью и временем работы алгоритма, а также менее подвержены застреванию в локальных минимумах.

4. В случае сигнала ЭЭГ пространство признаков имеет особенно высокую размерность за счет использования большого количества датчиков (каналов) снятия данных, в отдельных случаях их может быть более 100 и число признаков кратно возрастает. Методы понижения и отбора признаков в данном

контексте становятся особенно важны, выбор наиболее релевантных признаков необходим для снижения вычислительных затрат, возникающих из-за размерности. Бинаризованный метаэвристический алгоритм “стая птиц” может позволить понизить размерность признаков и упростить процесс создания нечеткого классификатора.

Глава 2. Метод и алгоритмы верификации субъекта на основе данных электроэнцефалограммы

2.1 Построение базы правил нечеткого классификатора с использованием кластеризации и метаэвристического алгоритма “стая птиц”

2.1.1 Предобработка данных ЭЭГ. Для создания большего количества данных записи из набора были разбиты на эпохи. В ходе этой процедуры из непрерывного сигнала ЭЭГ выделяются определенные временные окна. Эти временные окна называются "эпохами", и обычно они привязаны по времени к какому-либо событию, например, визуальному стимулу. Эпохи можно не привязывать к событию или стимулу, в таком случае разделение на эпохи применяется для искусственного увеличения объема набора данных и большей приближенности экспериментов машинного обучения к реальному миру (на практике предполагается к использованию небольшой сегмент, который можно быстро получить). Для деления данных на эпохи используется схема, представленная на Рисунке 2.1.

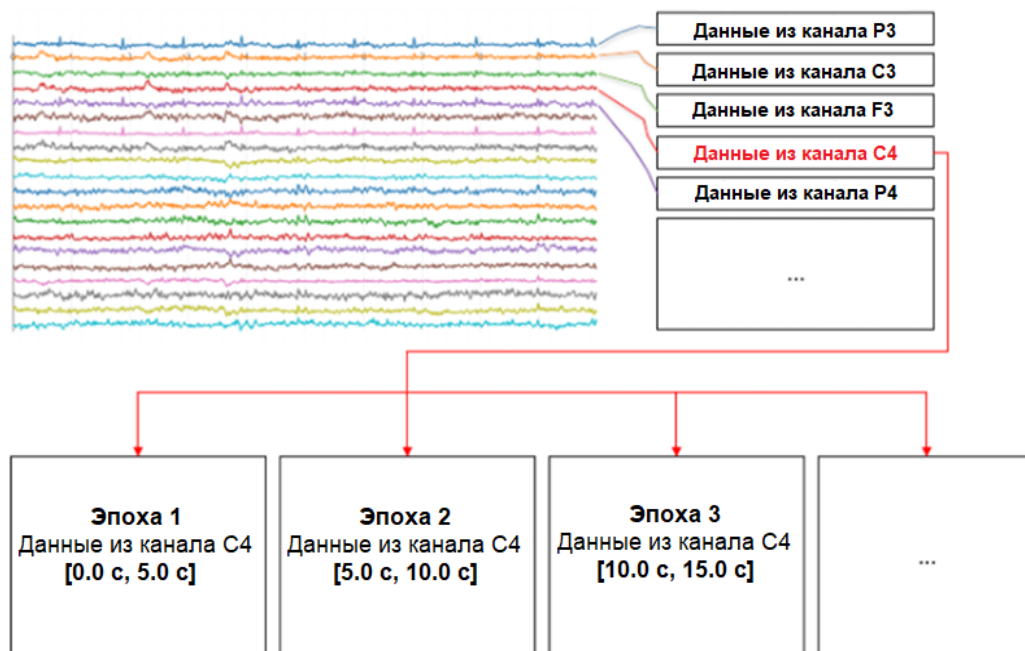


Рисунок 2.1 – Разбиение данных на эпохи

2.1.2 Извлечение признаков из сигнала ЭЭГ. В случае нечеткого классификатора также необходимо извлечь признаки из сигнала ЭЭГ. Для этой цели были использованы коэффициенты дискретного вейвлет-преобразования, был использован вейвлет Добеши 5 порядка, для декомпозиции сигнала на 5 уровней. Такое разделение позволяет извлечь определенные частоты сигнала ЭЭГ, соответствующие “ритмам мозга”. На основе коэффициентов вычислены среднее значение, стандартное отклонение и среднеквадратичное значение, используемые в качестве признаков, аналогично работам [162-164]. Схема выделения признаков представлена на Рисунке 2.2.




Рисунок 2.2 – Схема выделения признаков на основе дискретного вейвлет-преобразования

2.1.3 Алгоритм-аналог для построения базы правил нечеткого классификатора на основе экстремальных значений признаков. Алгоритм экстремальных значений признаков в классах (АЭПК) [165-168] позволяет создать базу правил минимально возможного объема, в которой каждому классу соответствует одно правило, а каждый признак представлен в правиле только одним термом. Для каждого признака каждого класса определяются экстремумы по признаковому описанию множества объектов:

$$\min_{class_{ik}} = \min_p (x_p^i | \mathbf{x}_p \in c_k), \quad (2.1)$$

$$\max_{class_{ik}} = \max_p (x_p^i | \mathbf{x}_p \in c_k), \quad (2.2)$$

где k – номер класса, i – номер признака, p – номер объекта, заданные ранее.

Далее формируется терм таким образом, чтобы функция принадлежности покрывала всю область в промежутке между парой экстремумов, а вершина терма находилась в центре этого отрезка. В работе были использованы термы Гауссова типа; координата вершины терма по оси абсцисс для i -го признака в j -ом правиле с меткой класса c_k задается следующим образом:

$$a_{ij} = (\max class_{ik} + \min class_{ik}) / 2. \quad (2.3)$$

Разброс определяется выражением ниже:

$$b_{ij} = (\max class_{ik} - \min class_{ik}) / 6. \quad (2.4)$$

Термы j -го класса объединяются в антецедентной части правила операцией конъюнкции. В консеквентной части правила приводится метка данного класса.

Результатом применения этого алгоритма является получение компактного классификатора, однако итоговая точность подобного полученного классификатора редко позволяет использовать его без оптимизации. Принцип формирования термов учитывает только экстремальные значения образцов, игнорируя остальные особенности данных. Поэтому при генерации структуры с помощью АЭПК необходимо применять настройку параметров термов, уточняющую координаты функций принадлежности для конкретной решаемой задачи классификации. Ниже приведен псевдокод алгоритма АЭПК.

Алгоритм АЭПК

Вход: Обучающие данные $data = \{(\mathbf{x}_p, \mathbf{c}_p) \mid p = 1, \dots, m\}$

Выход: База правил нечеткого классификатора θ .

1. $\theta = \{ \}$
 2. $i = 1$
 3. **пока** $i \leq$ число классов
 4. $j = 1$
 5. **пока** $j \leq$ число признаков
 6. Рассчитать a_{ij} по формуле $a_{ij} = (\max class_{ik} + \min class_{ik}) / 2$
-

-
7. Рассчитать σ_{ij} по формуле $b_{ij} = (\max class_{ik} - \min class_{ik}) / 6$
 8. $j = j + 1$
 9. добавить (a_{ij}, σ_{ij}) в θ .
 10. **конец пока**
 11. $i = i + 1$
 12. **конец пока**
-

2.1.4 Метаэвристический алгоритм “стая птиц”. Для генерации нечеткой системы кластеризацией был выбран метаэвристический алгоритм “стаи птиц” [169]. “Птицы” (поисковые частицы, особи) летают в многомерном пространстве поиска, переключаясь в различные моменты времени между поисковыми стратегиями. Особи также запоминают и обновляют свою лучшую позицию и позицию стаи (с наилучшим значением фитнес-функции). Считается, что информация о лучшем положении в стае распространяется мгновенно среди всех особей. В ходе работы алгоритм переключается между выполнением четырех различных поисковых стратегий. Первая поисковая стратегия задана следующим образом:

$$\theta_{i,j}^{t+1} = \theta_{i,j}^t + (p_{i,j} - \theta_{i,j}^t) * C * rand(0,1) + (g_j - \theta_{i,j}^t) * S * rand(0,1) \quad (2.5)$$

где $\theta_i^t = \{\theta_{i,1}^t, \theta_{i,2}^t, \dots, \theta_{i,D}^t\}$ - позиция i -й особи, соответствующая значениям параметров термов базы правил нечеткой системы на итерации t , $D = |\theta_i^t|$, $\mathbf{g} = \{g_1, g_2, \dots, g_D\}$ - особь с лучшим значением критерия $E(\theta)$ на итерации t , $\mathbf{p}_i = \{p_{i,1}, p_{i,2}, \dots, p_{i,D}\}$ - лучшая запомненная позиция i -й особи, $rand(a,b)$ - значение случайной равномерно распределенной величины в (a,b) , C и S - параметры алгоритма ($C > 0$, $S > 0$).

Вторая поисковая стратегия описывается следующими формулами:

$$\theta_{i,j}^{t+1} = \theta_{i,j}^t + (\bar{\theta}_j - \theta_{i,j}^t) * A1 * rand(0,1) + (p_{k,j} - \theta_{i,j}^t) * A2 * rand(-1,1) \quad (2.6)$$

$$A1 = a1 * \exp\left(\frac{(-N) * pFit_i}{sumFit + \varepsilon}\right) \quad (2.7)$$

$$A1 = a2 * \exp(\text{sgn}(pFit_i - pFit_k) * \frac{N * pFit_k}{sumFit + \varepsilon}) \quad (2.8)$$

где k – индекс случайным образом выбранной особи ($k \neq i$), $\bar{\theta}_j$ – среднее значения j -го параметра во всей популяции, N – число особей в стае, $pFit_i$ – запомненное лучшее значение критерия $E(\theta)$ для i -й особи, $sumFit = \sum_{i=1}^N pFit_i$, $a1$ и $a2$ – параметры алгоритма ($a1, a2 \in [0, 2]$).

На одном из этапов работы алгоритма происходит разделение стаи на две группы. Одна особь с лучшим значением $pFit$ относится к первой группе, особь с худшим значением $pFit$ отправляется во вторую группу. Оставшиеся особи распределяются по группам случайным образом.

Третья поисковая стратегия задана следующим образом:

$$\theta_{i,j}^{t+1} = \theta_{i,j}^t + \theta_{i,j}^t * \text{randn}(0,1) \quad (2.9)$$

где $\text{randn}(0,1)$ – значение нормально распределенной случайной величины с $\mu = 0$ и $\sigma = 1$.

Четвертая поисковая стратегия задается через следующую формулу:

$$\theta_{i,j}^{t+1} = \theta_{i,j}^t + (\theta_{k,j}^t - \theta_{i,j}^t) * FL * \text{rand}(0,1) \quad (2.10)$$

где k – индекс случайным образом выбранной особи из первой группы ($k \neq i$), FL – параметр алгоритма ($FL \in [0, 2]$).

Алгоритм является комбинацией последовательно работающих четырех поисковых стратегий, поэтому его легко модифицировать. Четвертую поисковую стратегию было решено заменить процессом полета Леви. Полет Леви — это случайное блуждание с большой вероятностью значительных отклонений от среднего, что выгодно отличает его от нормального распределения для задач глобального поиска при оптимизации. Эти значительные отклонения объясняются видом функции плотности вероятности, которая имеет “толстые” хвосты. Стратегия поиска с использованием полетов Леви выражается в виде формулы следующим образом:

$$\theta_{i,j}^{t+1} = \theta_{i,j}^t + \frac{\gamma * u}{|v|^{1/\beta}} \quad (2.11)$$

где γ – коэффициент прыжка Леви; параметр $\beta \in [0, 2]$; u, v – нормально распределенные величины ($u \sim N(0, \sigma_u^2), v \sim N(0, \sigma_v^2)$), $\sigma_v^2 = 1$,

$\sigma_u^2 = \left\{ \frac{\Gamma(1+\beta) \sin(\pi\beta/2)}{\Gamma[(1+\beta)/2] * 2^{(\beta-1)/2}} \right\}^{1/\beta}$, где $\Gamma(x)$ - гамма-функция. Блок-схема алгоритма

представлена на Рисунке 2.3. Вычислительная сложность данного метаэвристического алгоритма, согласно его авторам в [149], в худшем случае равна $O(N * M)$, M – число итераций.

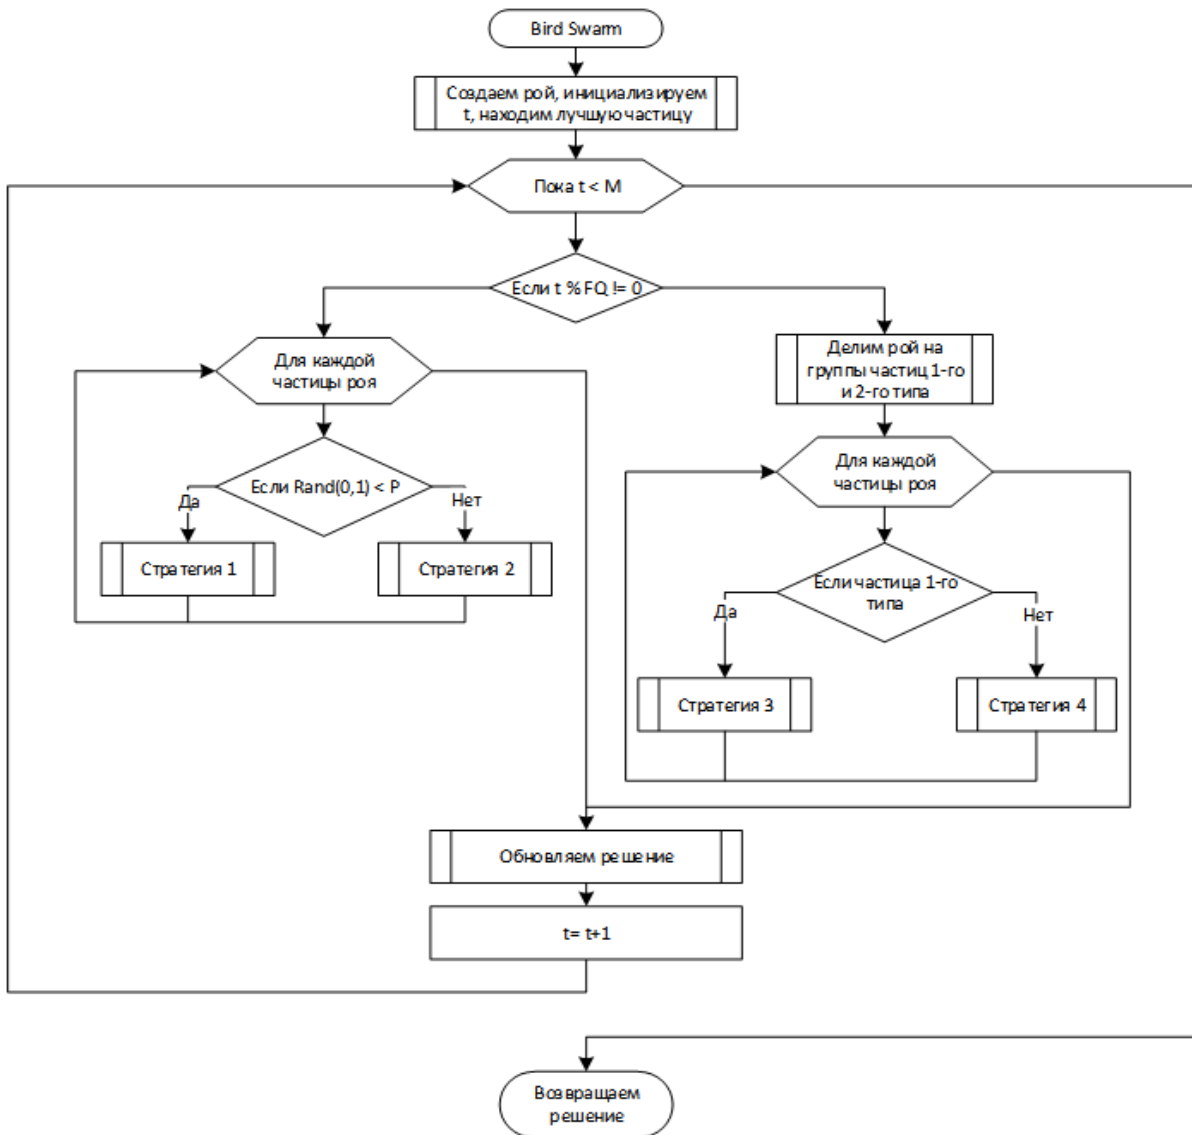


Рисунок 2.3 – Блок-схема алгоритма стаи птиц

2.1.5 Алгоритм-аналог генерации базы правил нечеткого классификатора кластеризацией. Алгоритмы кластеризации позволяют создавать структуру нечеткого классификатора, учитывая положение образцов относительно друг друга. Для этого можно использовать различные алгоритмы кластеризации, например алгоритм k -средних. В описанном алгоритм-аналоге генерации базы правил нечеткого классификатора кластеризацией [171], функция кластеризации данных передается в качестве параметра. После окончания работы алгоритма кластеризации для каждого кластера формируется по одному нечеткому правилу с термами Гауссова типа: координата вершины терма a_{ij} совпадает с координатой центра масс для i -ой переменной, разброс σ_{ij} формируется по минимальным и максимальным значениям признаков точек кластера. Консеквентом правила является класс, доминирующий в соответствующем кластере. Псевдокод алгоритма описан далее.

Алгоритм Генерация базы правил нечеткого классификатора кластеризацией на основе алгоритма кластеризации

Вход: Обучающие данные $data = \{(x_p, c_p) \mid p = 1, \dots, m\}$, число кластеров k , алгоритм кластеризации $Clustering$

Выход: База правил нечеткого классификатора θ .

1. $\theta = \{ \}$
 2. DataClusters, Centroids = $Clustering(x, k)$
 3. $i = 1$
 4. **пока** $i \leq K$
 5. $j = 1$
 6. **пока** $j \leq$ число признаков
 7. определить минимальное значение $min V_{ij}$ для i -го кластера j -го признака DataClusters $_{ij}$
 8. определить максимальное значение $max V_{ij}$ для i -го кластера j -го признака DataClusters $_{ij}$
-

-
9. $a_{ij} = Centroids_{ij}$
 10. $\sigma_{ij} = (\min V_{ij} + \max V_{ij}) / 6$
 11. определить консеквент c_{ij} , равный метке доминирующего в кластере класса
 12. добавить в θ (a_{ij}, σ_{ij}) с консеквентом c_{ij} .
 13. $j = j + 1$
 14. **конец пока**
 15. $i = i + 1$
 16. **конец пока**
-

2.1.6 Определение числа кластеров на основе алгоритма Autonomous Data Partitioning. Недостатком многих алгоритмов кластеризации, в том числе k -средних, является необходимость задания числа классов пользователем. Однако поиск оптимального количества кластеров является нетривиальной задачей. Актуальным направлением в машинном обучении считается разработка алгоритмов кластеризации, способных самостоятельно подбирать оптимальное число кластеров. Одним из таких алгоритмов является алгоритм автономного разделения данных (Autonomous Data Partitioning, ADP) [172]. Он автоматически распознает локальные максимумы плотности данных в таблице наблюдений и формирует на их основе «облака» – кластеры данных. Алгоритм состоит из нескольких этапов, в ходе которых проводится поиск всех уникальных образцов данных $U = \text{unique}(X) = \{\mathbf{u}_1, \mathbf{u}_2, \dots, \mathbf{u}_{L_Z}\}$ ($Z = |X|, L_Z = |U|$) и их частот встречаемости $\mathbf{Fr} = (fr_1, fr_2, \dots, fr_{L_Z})$, рассчитываются глобальные и локальные плотности данных. Локальная плотность для k -го уникального образца данных рассчитывается следующим образом:

$$D_{L_Z}(\mathbf{u}_k) = \frac{\sum_{j=1}^{L_Z} \sum_{l=1}^{L_Z} \|\mathbf{u}_j - \mathbf{u}_l\|^2}{2L_Z \sum_{l=1}^{L_Z} \|\mathbf{u}_k - \mathbf{u}_l\|^2}, \quad (2.12)$$

где $Z = |X|$.

Глобальная плотность для k -го уникального образца данных рассчитывается следующим образом:

$$D_{L_Z}^G(\mathbf{u}_k) = fr_k D_{L_Z}(\mathbf{u}_k) \quad (2.13)$$

Далее проводится сортировка данных по глобальной плотности и образец \mathbf{u}_1^* с наибольшей плотностью отбирается в конец нового пустого списка U^* :

$$\mathbf{u}_1^* = \arg \max_{q=1,2,\dots,L_Z} (D_{L_Z}^G(\mathbf{u}_q)) \quad (2.14)$$

На следующем шаге осуществляется поиск ближайшего по расстоянию к последнему элементу в U^* образца данных, который добавляется в U^* . Процесс итеративно повторяется, пока первоначальный список U не будет истощен.

Далее внутри отсортированного списка U^* определяются локальные максимумы глобальной плотности и заносятся в список U^{**} :

$$\begin{aligned} & \text{ЕСЛИ } (\text{sgn}(D_{L_Z}^G(\mathbf{u}_q^*) - D_{L_Z}^G(\mathbf{u}_{q+1}^*)) = 1) \text{ И } (\text{sgn}(D_{L_Z}^G(\mathbf{u}_{q-1}^*) - D_{L_Z}^G(\mathbf{u}_q^*)) = 1), \\ & \text{ТОГДА } (\mathbf{u}_q^* - \text{локальный максимум}, \mathbf{u}_{q^*}^{**}) \end{aligned} \quad (2.15)$$

где \mathbf{u}_q^* – элемент списка U^* , $q = \overline{1, L_Z}$, $\mathbf{u}_{q^*}^{**}$ – элемент списка U^{**} , $q^* = \overline{1, L_Z^{**}}$, sgn – функция возврата знака аргумента. Образцы данных распределяются по ближайшим локальным максимумам:

$$clusterlabel_r = \arg \min_{q^*=1,\dots,L_Z^{**}} (\|\mathbf{u}_r - \mathbf{u}_{q^*}^{**}\|), r = 1, \dots, L_Z, \quad (2.16)$$

$$cluster_e = \{\mathbf{u}_r \mid clusterlabel_r = e\}, e = 1, \dots, L_Z^{**}. \quad (2.17)$$

Для сформированных кластеров рассчитываются среднее значение принадлежащих точек (центроиды) $\boldsymbol{\eta}_{q^*}$, стандартное отклонение $\boldsymbol{\sigma}_{q^*}$ и число точек в кластере S_{q^*} .

Сформированные кластеры дополнительно фильтруются с объединением в более крупные кластеры. Для этого рассчитываются глобальные плотности относительно центроид кластеров и дополнительные характеристики:

$$D_Z^G(\boldsymbol{\eta}_{q^*}) = S_{q^*} \frac{\sum_{j=1}^{L_Z^{**}} \sum_{l=1}^{L_Z^{**}} \|\boldsymbol{\eta}_j - \boldsymbol{\eta}_l\|^2}{2L_Z^{**} \sum_{l=1}^{L_Z^{**}} \|\boldsymbol{\eta}_q - \boldsymbol{\eta}_l\|^2}, \quad (2.18)$$

$$\kappa_{L_Z} = \sum_{p^*=1}^{L_Z^{**}-1} \sum_{p^{**}=p^*+1}^{L_Z^{**}} \|\boldsymbol{\eta}_{p^*} - \boldsymbol{\eta}_{p^{**}}\| / (L_Z^{**}(L_Z^{**} - 1)), \quad (2.19)$$

$$\gamma_{L_Z} = \frac{\sum_{\mathbf{g}, \mathbf{h} \in \{\boldsymbol{\eta}_q\}_{L_Z^{**}}, \mathbf{g} \neq \mathbf{h}, \|\mathbf{g} - \mathbf{h}\| \leq \kappa_{L_Z}} \|\mathbf{g} - \mathbf{h}\|}{\left| \{ \{\mathbf{g}, \mathbf{h}\} \mid \mathbf{g}, \mathbf{h} \in \{\boldsymbol{\eta}_q\}_{L_Z^{**}}, \mathbf{g} \neq \mathbf{h}, \|\mathbf{g} - \mathbf{h}\| \leq \kappa_{L_Z} \} \right|}, \quad (2.20)$$

$$\lambda_{L_Z} = \frac{\sum_{\mathbf{g}, \mathbf{h} \in \{\boldsymbol{\eta}_q\}_{L_Z^{**}}, \mathbf{g} \neq \mathbf{h}, \|\mathbf{g} - \mathbf{h}\| \leq \gamma_{L_Z}} \|\mathbf{g} - \mathbf{h}\|}{\left| \{ \{\mathbf{g}, \mathbf{h}\} \mid \mathbf{g}, \mathbf{h} \in \{\boldsymbol{\eta}_q\}_{L_Z^{**}}, \mathbf{g} \neq \mathbf{h}, \|\mathbf{g} - \mathbf{h}\| \leq \gamma_{L_Z} \} \right|}. \quad (2.21)$$

Каждый центроид сравнивается с соседними и проверяется на критерий локального максимума:

$$\begin{aligned} &\text{ЕСЛИ } (D_{L_Z}^G(\boldsymbol{\eta}_{q^*}) = \max(\{Neighbours_{q^*}, D_{L_Z}^G(\boldsymbol{\eta}_{q^*})\})), \\ &\text{ТОГДА } (\boldsymbol{\eta}_{q^*} - \text{локальный максимум}, \boldsymbol{\eta}_{q^*}^*), \end{aligned} \quad (2.22)$$

где $Neighbours_{q^*}$ - глобальные плотности центроид, расстояние до которых от $\boldsymbol{\eta}_{q^*}$ меньше $\lambda_{L_Z}/2$.

Сформированный список $\{\boldsymbol{\eta}_{q^*}^*\}, q^* = \overline{1; L_Z^{**}}$ определяет новые центры для формирования кластеров. Процедура фильтрации и выделения более общих кластеров на основе центроид повторяется до тех пор, пока расстояние между всеми центроидами не будет больше $\lambda_{L_Z}/2$. Полученное число кластеров N_{cl} используется для задания параметра алгоритма k -средних.

Псевдокод алгоритма автономного разделения данных описан далее.

Алгоритм Определение числа кластеров на основе алгоритма Autonomous Data Partitioning.

Вход: таблица наблюдений.

Выход: N_{cl} - число кластеров.

1. Внесение всех уникальных образцов данных во множество U , определение вектора частот встречаемости уникальных образцов \mathbf{Fr} ;
 2. Расчет глобальной плотности для каждого уникального образца;
 3. Сортировка по глобальной плотности и получение списка U^* ;
-

-
4. Определение на основе U^* локальных максимумов глобальной плотности и составление списка U^{**} ;
 5. Вычисление $\eta_{q^*}, \sigma_{q^*}, S_{q^*}, \lambda_{Lz}$;
 6. Фильтрация кластеров;
 7. Получение итогового количества кластеров N_{cl}
-

2.1.7 Алгоритм построения базы правил нечеткого классификатора с использованием кластеризации и метаэвристического алгоритма “стая птиц”.

В данной работе предлагается гибридный авторский метод генерации базы правил с использованием k -средних и метаэвристической кластеризации, на основе метаэвристического алгоритма “стая птиц” [173]. Использование k -средних заключается в использовании идеи оптимизации положения k центроид и перераспределения точек по центроидам, для достижения наилучшего качества кластеризации. В этом случае генерировалась случайным образом популяция векторов $\mathbf{CS} = [\mathbf{CS}_1, \dots, \mathbf{CS}_i, \dots, \mathbf{CS}_{size}]$ ($size$ - размер популяции, $|\mathbf{CS}_i| = R * n * pl$, pl – количество параметров выбранной функции принадлежности), каждый из которых представляет собой совокупность центроид-правил. Для определения числа правил предлагается использовать алгоритм Autonomous Data Partitioning. Вычислительная сложность бинаризованого метаэвристического алгоритма, аналогично оригиналу в [149], в худшем случае равна $O(size * MaxGen)$, $MaxGen$ – число итераций. Ниже приведен псевдокод предлагаемого алгоритма.

Алгоритм Генерация нечеткой системы с помощью метаэвристической кластеризации:

Вход: таблица наблюдений (\mathbf{X}, \mathbf{Y}) , $\mathbf{X} = [\mathbf{x}_1, \dots, \mathbf{x}_i, \dots, \mathbf{x}_l]$, $\mathbf{Y} = [y_1, \dots, y_i, \dots, y_l]$, $size, n, R, pl$, **params** - вектор параметров метаэвристического алгоритма, $type$ - тип функции принадлежности, $metaheuristic$ – функция, выполняющая оптимизацию метаэвристическим алгоритмом BSA, $ffclust$ – фитнес-функция.

Выход: \mathbf{FS}_{best} - сгенерированная база правил.

1. $\mathbf{CS} \leftarrow generate(type, size, pl, R, n)$ - генерация популяции баз правил;
-

2. $\mathbf{CS} \leftarrow \text{metaheuristic}(\text{params}, \mathbf{CS}, \mathbf{X}, \mathbf{Y}, \text{ffclust})$

3. Выбор лучшей базы правил \mathbf{CS}_{best} по вычисленному лучшему значению $\text{ffclust}(\mathbf{CS}_j)$

4. Генерация базы правил \mathbf{FS}_{best} на основе вектора \mathbf{CS}_{best}

Алгоритм Фитнесс-функция ffclust :

Вход: таблица наблюдений (\mathbf{X}, \mathbf{Y}) , $\mathbf{X} = [\mathbf{x}_1, \dots, \mathbf{x}_i, \dots, \mathbf{x}_l]$, $\mathbf{Y} = [y_1, \dots, y_i, \dots, y_l]$, $\text{size}, n, R, pl, \text{type}$, $\mathbf{CS}_j = [\mathbf{c}_{j1}, \dots, \mathbf{c}_{ji}, \dots, \mathbf{c}_{jR}]$.

Выход: ffvalue .

1. Вычисление матрицы эвклидовых расстояний $\mathbf{D}_{R \times l} = (d_{km})$ между центроидами-правилами \mathbf{c}_{ji} и векторами данных \mathbf{x}_i из таблицы \mathbf{X} ;

2. $\text{Clusters} \leftarrow \emptyset$

3. **пока** $m=1..l$

4. $\text{nearest} \leftarrow \arg \min_i d_{km}$
 $k \in 1..R, m \in 1..l$

5. $\text{Clusters}_{\text{nearest}} \leftarrow \text{Clusters}_{\text{nearest}} \cup \mathbf{x}_m$

6. **конец пока**

8. $\text{FS} \leftarrow \emptyset$

9. **пока** $m=1..R$

10. **если** $|\text{Cluster}_m| > 0$

11. Сгенерировать правило Rule на основе мин. и макс. значений признаков в Cluster_m

12. **иначе**

13. Сгенерировать правило Rule на основе мин. и макс. значений признаков в \mathbf{X}

14: $\text{FS} \leftarrow \text{FS} \cup \text{Rule}$

15: **конец пока**

16: $\text{ffvalue} \leftarrow \text{acc}(\text{FS}, \mathbf{X}, \mathbf{Y})$

2.2 Алгоритм отбора признаков с использованием функции трансформации и метаэвристического алгоритма “стая птиц”

Классический подход к бинаризации метаэвристик заключается в использовании функций трансформации, которые позволяют отображать непрерывные значения на бинарную область. Этот метод получил широкое распространение благодаря отсутствию необходимости внедрения значительных изменений в алгоритм: все операторы метаэвристики остаются прежними, вводится только шаг расчета значения функции трансформации при вычислении целевой функции и возврате результата работы алгоритма. В работе предлагается использовать оригинальный авторский алгоритм отбора признаков с использованием V-образной функции трансформации и метаэвристического алгоритма “стая птиц”. Рассмотрим более подробно бинаризацию метаэвристики “стая птиц”. При использовании метаэвристики “стая птиц” для отбора признаков $\theta_{i,j}^t$ - позиция каждой особи, которая интерпретируется как бинарная переменная, определяющая исключен ли некоторый признак из рассмотрения на итерации t . Для бинаризации метаэвристики в качестве функции трансформации может выступать S-образная функция (Sigm) [174, 175]:

$$\text{Если } 0.5 < \frac{1}{1 + e^{-\theta_{i,j}^t}}, \text{ то } \theta_{i,j}^t = 1, \text{ иначе } 0. \quad (2.23)$$

Для обновления элемента в бинарном векторе признаков возможно использование другого правила, где используется V-образная функция (V):

$$\text{Если } 0.5 < \left| \frac{\theta_{i,j}^t}{\sqrt{1 + \theta_{i,j}^t{}^2}} \right|, \text{ то } \theta_{i,j}^t = 1, \text{ иначе } 0. \quad (2.24)$$

В рамках исследования использовано еще одно правило (Tanh):

$$\text{Если } |\tanh(\theta_{i,j}^t)| > 0.5, \text{ то } \theta_{i,j}^t = 1, \text{ иначе } 0. \quad (2.25)$$

Также было рассмотрено другое, более простое правило (Naive):

$$\text{Если } \theta_{i,j}^t > 0.5 \text{ то } \theta_{i,j}^t = 1, \text{ иначе } 0. \quad (2.26)$$

Вычислительная сложность бинаризованого метаэвристического алгоритма, аналогично оригиналу в [149], в худшем случае равна $O(N * MaxGen)$, $MaxGen$ – число итераций. Ниже приведен псевдокод предлагаемого алгоритма.

Алгоритм Бинарный алгоритм “стая птиц”

Вход: T – обучающие данные, N – размер популяции, $MaxGen$ – количество итераций, trf - функция трансформации, FQ – параметр алгоритма, P – параметр алгоритма

Выход: бинарный вектор s_{best} , указывающий на информативные признаки.

1. Инициализировать популяцию $S = \{s_1, s_2, \dots, s_N\}$, $s_i = \text{rand}\{0, 1\}^n$;
 2. Инициализировать счётчик популяции $i = 1$;
 3. **пока** $i \leq N$
 4. Создать обучающие данные T^i из T с признаками s_i ;
 5. Построить классификатор на T^i и вычислить значение целевой функции f_i на основе s_i и функции трансформации trf ;
 6. $i = i + 1$;
 7. **конец пока**
 8. Определить лучшее решение s_{best} в S ($\forall i f_{best} \leq f_i$)
 9. Инициализировать счётчик итераций $t = 1$;
 10. **пока** $t \leq MaxGen$
 11. Инициализировать популяцию вещественных решений Θ на основе S
 12. Инициализировать счётчик популяции $i = 1$;
 13. **Если** $(t \bmod FQ \neq 0)$:
 14. **пока** $i \leq N$:
 15. **Если** $(\text{rand}(0, 1) < P)$:
 16. Обновить решение θ_i по формуле стратегии 1;
 17. **Иначе:**
 18. Обновить решение θ_i по формуле стратегии 2;
-

-
19. Скорректировать θ_i , если вектор выходит за пределы пространства поиска;
 20. Обновить бинарное решение s_i через функцию трансформации trf ;
 21. Создать обучающие данные T' из T с признаками s_i ;
 22. Построить классификатор на T' и вычислить значение целевой функции f_i на основе s_i ;
 23. $i = i + 1$;
 24. **конец пока**
 25. **Иначе:**
 26. Разделить частицы на 1-й и 2-й тип
 27. **пока** $i \leq N$:
 28. **Если** частица 1-го типа:
 29. Обновить решение θ_i по формуле стратегии 3;
 30. **Иначе:**
 31. Обновить решение θ_i по формуле стратегии 4;
 32. Скорректировать θ_i , если вектор выходит за пределы пространства поиска;
 33. Обновить бинарное решение s_i через функцию трансформации trf ;
 34. Создать обучающие данные T' из T с признаками s_i ;
 35. Построить классификатор на T' и вычислить значение f_i на основе s_i и функции трансформации trf ;
 36. $i = i + 1$;
 37. **конец пока**
 38. $t = t + 1$;
 39. Обновить наилучшее решение s_{best} в S ($\forall i f_{best} \leq f_i$)
 40. **конец пока**
-

2.3 Метод верификации субъекта на основе данных электроэнцефалограммы с использованием извлечения признаков на основе преобразования Холл-Гильберта и метрического обучения

2.3.1 Архитектура модели-аналога на основе дискретного вейвлет-преобразования. В качестве наиболее простой модели-аналога выбран трехслойный перцептрон, принимающий на вход вектор признаков на основе дискретного вейвлет преобразования. Признаки на основе коэффициентов дискретного вейвлет преобразования рассчитываются по описанной в разделе 2.1.1 схеме. В данной модели и остальных в работе в качестве функции активации используется функция SiLU (Sigmoid Linear Unit). Архитектура приведена в Таблице 2.1. (Linear – полносвязный слой, Flatten – слой преобразования размерности в одномерный вектор, Output – выходной слой сети, не изменяющий и не преобразующий поступающие данные;).

Таблица 2.1 - Архитектура сети на основе дискретного вейвлет преобразования

Слой	Число фильтров / нейронов	Размер фильтров / ядер	Размерность входа	Число параметров	Функция активации выхода
Linear	512	-	1152	590336	SiLU
Linear	256	-	525	131328	SiLU
Linear	128	-	256	32896	-
Output	-	-	128	-	-

2.3.2 Архитектура модели-аналога на основе преобразования Гильберта-Хуанга. Спектрограммы данных каналов ЭЭГ, полученные с помощью преобразования Гильберта-Хуанга, представляют собой, по существу, двумерные изображения (Рисунок 2.4). Однако эти два измерения представляют принципиально разные единицы измерения, одна из которых — частотная мощность, а другая — время. Поэтому пространственная инвариантность, которую обеспечивают двумерные CNN, может не подойти для рассматриваемой задачи. В данной работе рассматривается представление спектрограммы в виде набора сложенных (“stacked”) временных рядов для разных частотных интервалов. В таком случае, в случае представления спектрограммы как двумерной матрицы, каждый частотный интервал (строка матрицы) рассматривается как отдельная временная серия. Если спектральное представление эпохи ЭЭГ имеет представление размерности [число каналов ЭЭГ \times N диапазонов частотной модуляции \times время], то, в случае модели на основе одномерных сверток, данные преобразовываются к размерности [(число каналов ЭЭГ * N диапазонов частотной модуляции) \times время]. Оба варианта архитектур представлены в Таблице 2.2 и Таблице 2.3.

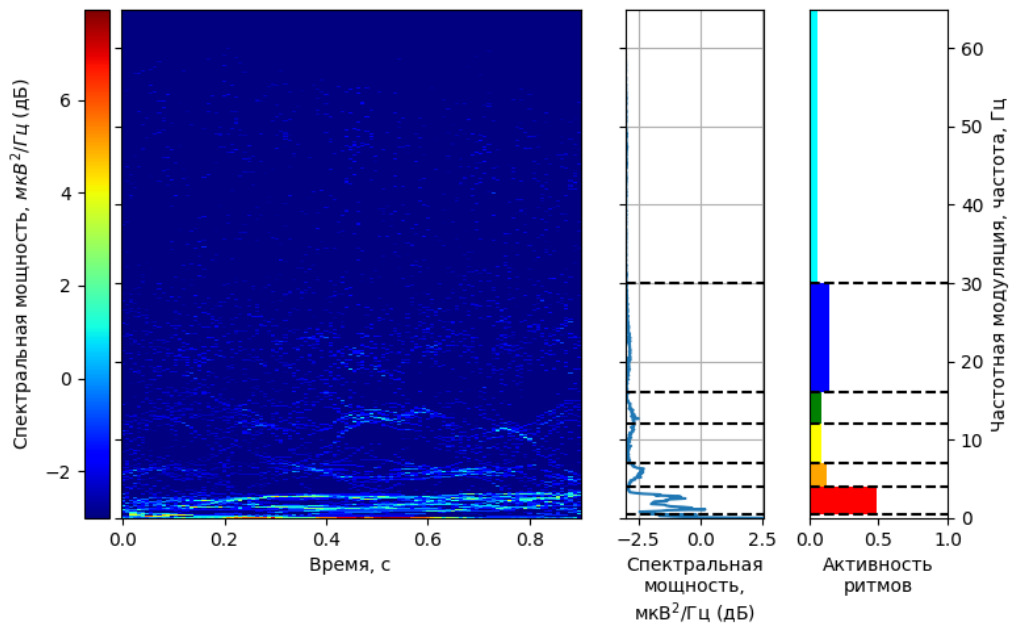


Рисунок 2.4 – Спектрограмма данных ЭЭГ, полученная с помощью преобразования Гильберта-Хуанга

Таблица 2.2 - Архитектура сети на основе преобразования Гильберта-Хуанга и одномерных сверток

Слой	Число фильтров / нейронов	Размер фильтров / ядер	Размерность входа	Число параметров	Функция активации выхода
Conv1D (padding=1)	256	2	[15*64, 115]	491776	-
Maxpool1D	-	2	[256, 116]	-	-
BatchNorm1D	-	-	[256, 59]	512	SiLU
Conv1D	128	2	[256, 59]	16448	-
Maxpool1D	-	2	[128, 58]	-	-
BatchNorm1D	-	-	[128, 29]	256	SiLU
Conv1D	64	2	[128, 29]	16448	-
Maxpool1D	-	2	[64, 28]	-	-
BatchNorm1D	-	-	[64, 14]	128	SiLU
Conv1D	32	2	[64, 14]	4128	-
Maxpool1D	-	2	[32, 13]	-	-
BatchNorm1D	-	-	[32, 6]	128	SiLU
Flatten	-	-	[32*6]	-	-
Linear	128	-	[192]	24704	-
Output	-	-	[128]	-	-

Таблица 2.3 - Архитектура сети на основе преобразования Гильберта-Хуанга и двумерных сверток

Слой	Число фильтров / нейронов	Размер фильтров / ядер	Размерность входа	Число параметров	Функция активации выхода
Conv2D (padding=1)	32	(2,2)	[64, 15, 115]	8224	-
Maxpool2D	-	(2,2)	[32, 16, 116]	-	-
BatchNorm2D	-	-	[32, 9, 59]	64	SiLU
Conv2D	16	(2,2)	[16, 9, 59]	2064	-
Maxpool2D	-	(2,2)	[16, 8, 58]	-	-
BatchNorm2D	-	-	[16, 4, 29]	32	SiLU
Conv2D	16	(2,2)	[16, 4, 29]	1040	-
Maxpool2D	-	(2,2)	[16, 3, 28]	-	-
BatchNorm2D	-	-	[16, 1, 14]	32	SiLU
Flatten	-	-	[16*14]	-	-
Linear	128	-	[224]	28800	-
Output	-	-	[128]	-	-

2.3.3 Метод и архитектура модели верификации субъекта на основе данных электроэнцефалограммы с использованием извлечения признаков с помощью преобразования Холо-Гильберта и метрического обучения. Метод спектрального анализа Холо-Гильберта (Holo-Hilbert Spectral Analysis, HNSA) используется для устранения недостатков традиционных методов спектрального анализа и обеспечения полного информационного представления нелинейных и нестационарных данных. Он использует вложенное эмпирическое модовое разложение (EMD) и преобразование Гильберта-Хуанга (Hilbert-Huang Transform, HHT) для выявления присущих амплитудных и частотных модуляций, часто присутствующих в нелинейных системах. HNSA учитывает все взаимодействия: аддитивные и мультипликативные, внутримодовые и межмодовые, стационарные и нестационарные, линейные и нелинейные. Префикс Holo в HNSA обозначает многомерное представление с аддитивными и мультипликативными возможностями. Размерность данного представления выглядит следующим образом – [N диапазонов частотной модуляции (Frequency Modulation, FM) \times M диапазонов амплитудной модуляции (Amplitude Modulation, AM) \times время]. Размерность обычного представления на основе преобразования Гильберта-Хуанга выглядит следующим образом – [N диапазонов FM \times время] [176-179].

На Рисунке 2.5 показаны различные варианты усреднения многомерного представления сигнала на основе преобразования Холо-Гильберта по одной из осей (по частотной модуляции, по амплитудной модуляции, по времени). Аналогично предыдущему разделу, рассматривается две модели на основе преобразования Холо-Гильберта: сеть на основе трехмерных сверток (Таблица 2.4) и на основе одномерных сверток (Таблица 2.5). Во всех описанных моделях в разделе 2.3 в первом слое используется заполнение (“padding”, дополнение нулями) таким образом, чтобы сохранить размерность входа (кроме размеров каналов) для корректной обработки значений краевых значений. Значения, полученные после преобразования Гильберта-Хуанга и Холо-Гильберта довольно небольшие,

поэтому значения спектральной мощности преобразуются в относительные логарифмические единицы – децибелы.

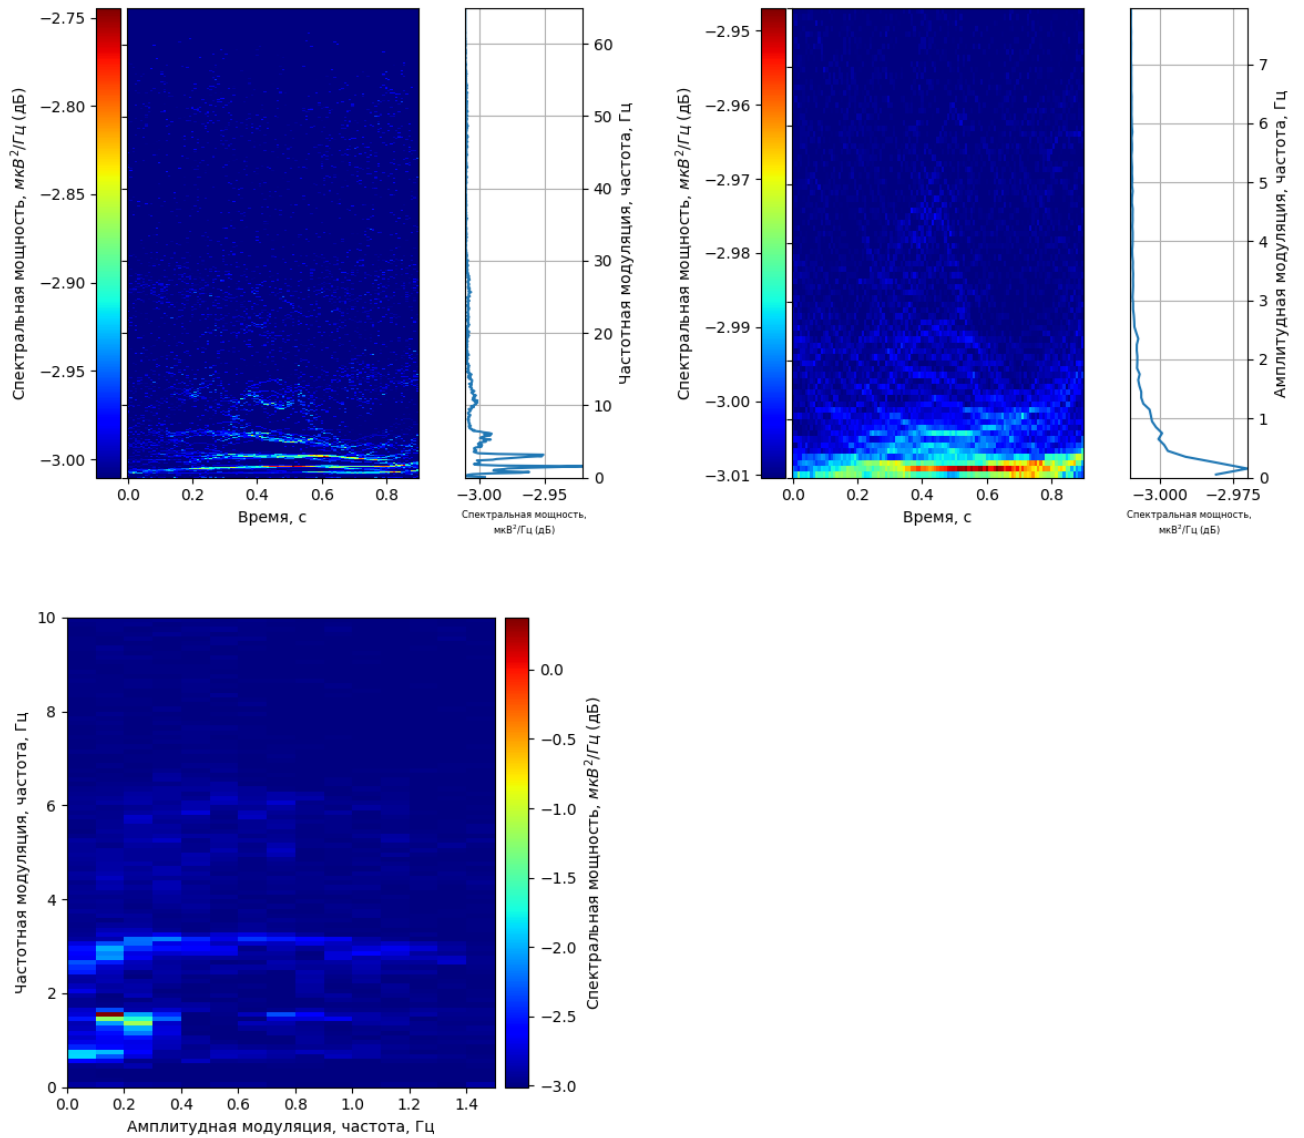


Рисунок 2.5 – Представление данных ЭЭГ, полученное с помощью преобразования Холо-Гильберта и усредненное по одной из осей

Таблица 2.4 - Архитектура сети на основе преобразования Холо-Гильберта и трехмерных сверток

Слой	Число фильтров / нейронов	Размер фильтров / ядер	Размерность входа	Число параметров	Функция активации выхода
Conv3D (padding=1)	32	(2, 2, 2)	[64, 15, 2, 115]	16416	-
Maxpool3D	-	(2, 2, 2)	[32, 16, 3, 116]	-	-
BatchNorm3D	-	-	[32, 9, 2, 59]	64	SiLU
Conv3D	16	(2, 2, 2)	[32, 9, 2, 59]	2064	-
Maxpool3D	-	(2, 2, 2)	[16, 8, 2, 58]	-	-
BatchNorm3D	-	-	[16, 4, 1, 29]	32	SiLU
Conv3D	16	(2, 1, 2)	[16, 4, 1, 29]	1040	-
Maxpool3D	-	(2, 1, 2)	[16, 3, 1, 28]	-	-
BatchNorm3D	-	-	[16, 1, 1, 14]	32	SiLU
Flatten	-	-	[224]	-	-
Linear	128	-	[128]	28800	-
Output	-	-	[128]	-	-

Таблица 2.5 - Архитектура сети на основе преобразования Холо-Гильберта и одномерных сверток

Слой	Число фильтров / нейронов	Размер фильтров / ядер	Размерность входа	Число параметров	Функция активации выхода
Conv1D (padding=1)	1024	2	(64*15*2, 115)	7865344	-
Maxpool1D	-	2	(1024, 116)	-	-
BatchNorm1D	-	-	(1024, 59)	2048	SiLU
Conv1D	512	2	(1024, 59)	1049088	-
Maxpool1D	-	2	(512, 58)	-	-
BatchNorm1D	-	-	(512, 29)	1024	SiLU
Conv1D	256	2	(1024, 29)	262400	-
Maxpool1D	-	2	(256, 28)	-	-
BatchNorm1D	-	-	(256, 14)	512	SiLU
Conv1D	128	2	(256, 14)	65664	-
Maxpool1D	-	2	(128, 13)	-	-
BatchNorm1D	-	-	(128, 6)	256	SiLU
Conv1D	64	2	(128, 6)	16448	-
Maxpool1D	-	2	(64, 5)	-	-
BatchNorm1D	-	-	(64, 2)	128	SiLU
Flatten	-	-	(128)	-	-
Linear	128	-	(128)	16512	-
Output	-	-	(128)	-	-

На Рисунке 2.6 показана общая схема метода (систематизированная совокупность действий для решения задачи верификации с использованием построенной нейросетевой модели).

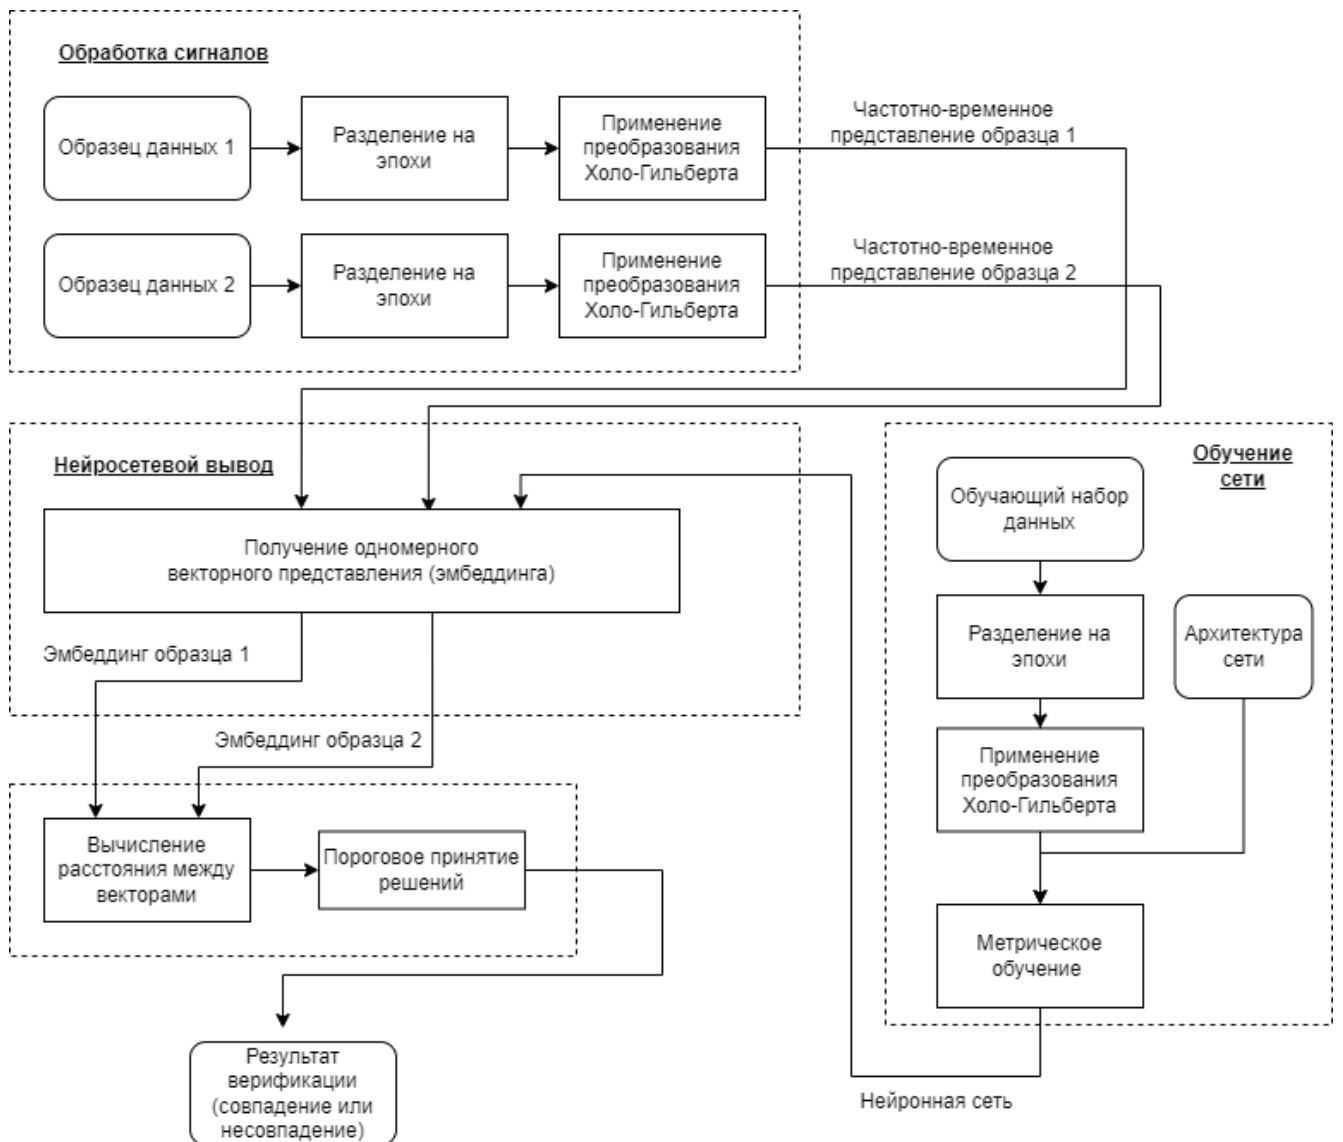


Рисунок 2.6 – Схема предлагаемого метода

2.4 Выводы

1. Предложен гибридный алгоритм построения базы правил нечеткого классификатора, особенностью которого является совместное использование алгоритма кластеризации k -средних и метаэвристического алгоритма “стая птиц”. Для определения числа кластеров используется алгоритм Autonomous Data Partitioning. Используемый метаэвристический алгоритм совмещает 4 поисковые стратегии, реализующих как глобальный, так и локальный поиск. Предложенный

комплексный подход ориентирован на улучшение точности сгенерированной базы правил для нечеткого классификатора.

2. Разработан алгоритм отбора признаков, особенностью которого является использование V-образной функции трансформации и метаэвристического алгоритма “стая птиц”. Предложенный метод ориентирован на улучшение точности нечеткого классификатора путем снижения числа признаков, уменьшения поискового пространства.

3. Разработан оригинальный метод верификации субъекта на основе данных ЭЭГ, отличительной особенностью которого является использование извлечения признаков с помощью преобразования Холо-Гильберта и метрического обучения. Применение метрического обучения позволяет не привязываться к жестко заданному списку классовых меток (списку субъектов), а преобразование Холо-Гильберта позволит учесть все взаимодействия: аддитивные и мультипликативные, внутримодовые и межмодовые, стационарные и нестационарные, линейные и нелинейные, для улучшения точности верификации субъекта.

Глава 3. Исследование эффективности разработанных метода и алгоритмов

3.1 Используемые наборы данных и предобработка, протоколы оценки

Был использован уже ранее упомянутый в разделе 1.4 набор данных EEG Motor Movement/Imagery Dataset [117, 118] с портала Physionet, содержащий 1-минутные и 2-минутные записи 109 человек. Первоначально записи ЭЭГ представляют собой наборы по 64 временные серии (соответственно числу электродов), записанных с частотой дискретизации 160 Гц. Участники совершали двигательные задания и задачи представления, пока велась запись 64-канального ЭЭГ сигнала с использованием системы VCI2000. Данные были разделены на эпохи длительностью равной 1 секунде. Были использованы данные ЭЭГ только для состояния "глаза открыты" и "глаза закрыты", чтобы конечная система была более удобна для субъекта и не требовала от него выполнения дополнительных задач в ходе верификации. После обработки имеем следующую размерность набора данных - [8715 образцов, 64 канала]. Каждый образец представляет собой временной ряд из 161 временных отсчетов, поэтому можно представить размерность в следующем виде - [8715 образцов, 64 канала, 161 временной отсчет]. Для упрощения процесса обучения было произведено понижение частоты дискретизации сигнала до частоты 125 Гц. После этого набор данных имеет следующую размерность - [8715 образцов, 64 канала, 126 временных отсчетов]. Дополнительная фильтрация или предобработка до применения метода Гильберта-Хуанга и Холо-Гильберта не проводилась.

Для данной работы использовалась реализация методов Гильберта-Хуанга и Холо-Гильберта в пакете EMD [181] на языке Python. В ходе применения данных методов производится декомпозиция сигнала на отдельные модовые составляющие (Рисунок 3.1). Для этого используется метод sift [97]. Суть метода сводится к определению локальных экстремумов сигнала и подгонке огибающей к этим экстремумам. Затем вычисляется разность между сигналом и его огибающей, и процесс повторяется для этой разности до тех пор, пока не будет получена локально гладкая IMF. Полученные IMF отражают различные масштабы колебаний сигнала,

причем первая IMF отражает самые высокочастотные колебания, а последняя - самые низкочастотные. Итоговый остаточный сигнал, полученный после выделения всех IMF, представляет собой тренд исходного сигнала (Residue, в данном случае обозначена как IMF-7).




Рисунок 3.1 – Пример разложения данных сегмента ЭЭГ на IMF

EMD является локально адаптивным алгоритмом, из-за этого одной из проблем является смешение мод, возникающее в процессе EMD-разложения. Под смешением мод понимается ситуация, когда IMF, полученная в результате EMD-разложения, имеет компоненты с разными частотами. Одним из решений этой проблемы является масочный sift. Это простой прием, который эффективно устанавливает нижнюю границу на частотное содержание, которое может попасть в конкретную IMF. Перед запуском процесса sift во временной ряд добавляется известный маскирующий сигнал. Любые сигналы, частота которых ниже, чем у этой маски, должны быть проигнорированы в пользу этого известного сигнала. После этого можно удалить известный маскирующий сигнал, чтобы восстановить IMF. В работе использовался метод маскирующего sift с ограничением на максимальное число извлекаемых компонент, равным 10. После извлечения компонент к сигналу применяется преобразование Гильберта-Хуанга, для извлечения мгновенной частоты, амплитуды и фазы каждой из компонент (Рисунок 3.2). На основе вычисленных мгновенных частот и амплитуд строится спектрограмма сигнала.

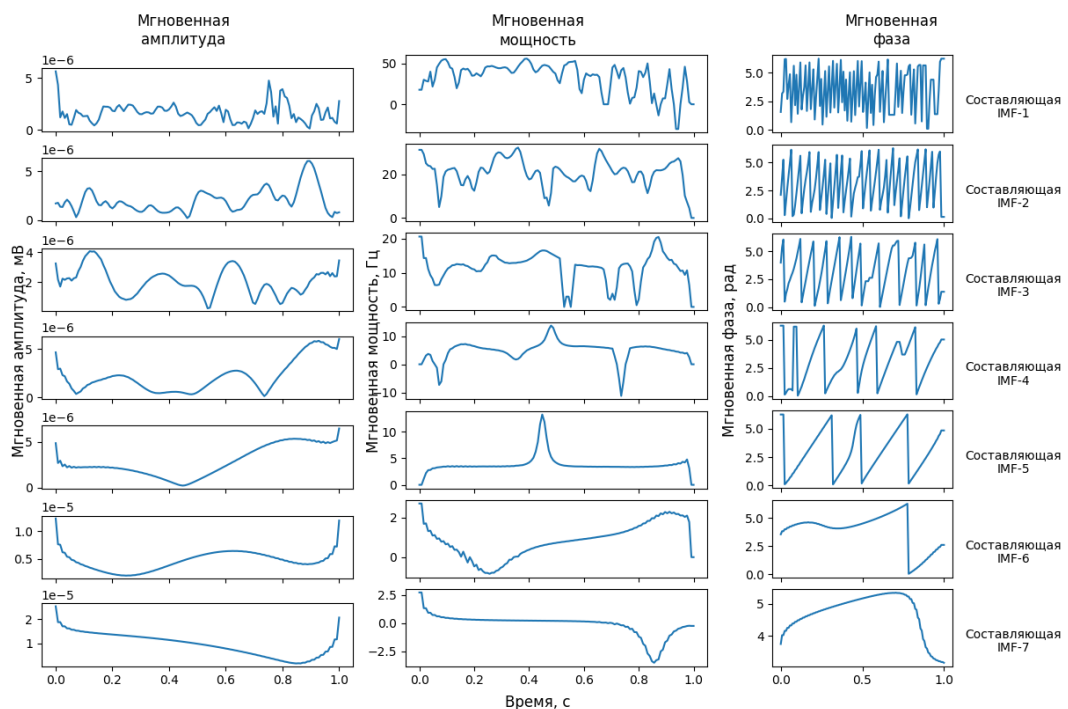


Рисунок 3.2 – Извлеченные мгновенная частота, амплитуда и фаза для IMF-КОМПОНЕНТ

Для применения метода Холо-Гильберта и Гильберта-Хуанга необходимо определить границы интересующего частотного диапазона. Согласно теореме Найквиста, был выбран диапазон от 0,0 Гц до 60,0 Гц. После этого были сгенерированы спектрограммы для данного диапазона для всего набора данных. На Рисунке 3.3 показана усредненная по всем каналам и эпохам субъектов спектрограмма, полученная с помощью метода Гильберта-Хуанга. В области 60 Гц выделяется пик спектральной мощности, показывающий наводку электрооборудования при снятии данных ЭЭГ. Большая часть спектральной мощности сосредоточена в области низких частот, отражая масштабирование спектра мощности по принципу $1/f$ - доминирующая структура спектра мощности ЭЭГ представляет собой убывающую функцию с меньшей мощностью на более высоких частотах.

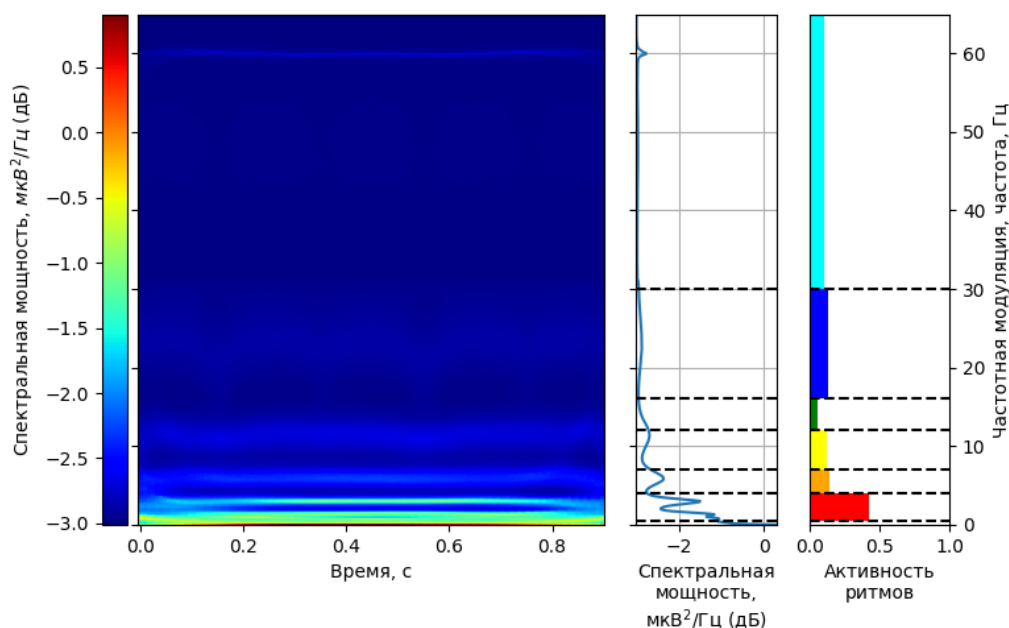


Рисунок 3.3 – Усредненная по всем каналам и эпохам субъектов спектрограмма, полученная с помощью метода Гильберта-Хуанга

Для итогового процессинга данных был выделен диапазон частотной модуляции 0–60 Гц с 15 частотными суб-диапазонами по 4 Гц. После этого набор данных имеет следующую размерность - [8715 образцов, 64 канала, 15 FM диапазонов, 126 временных отсчетов].

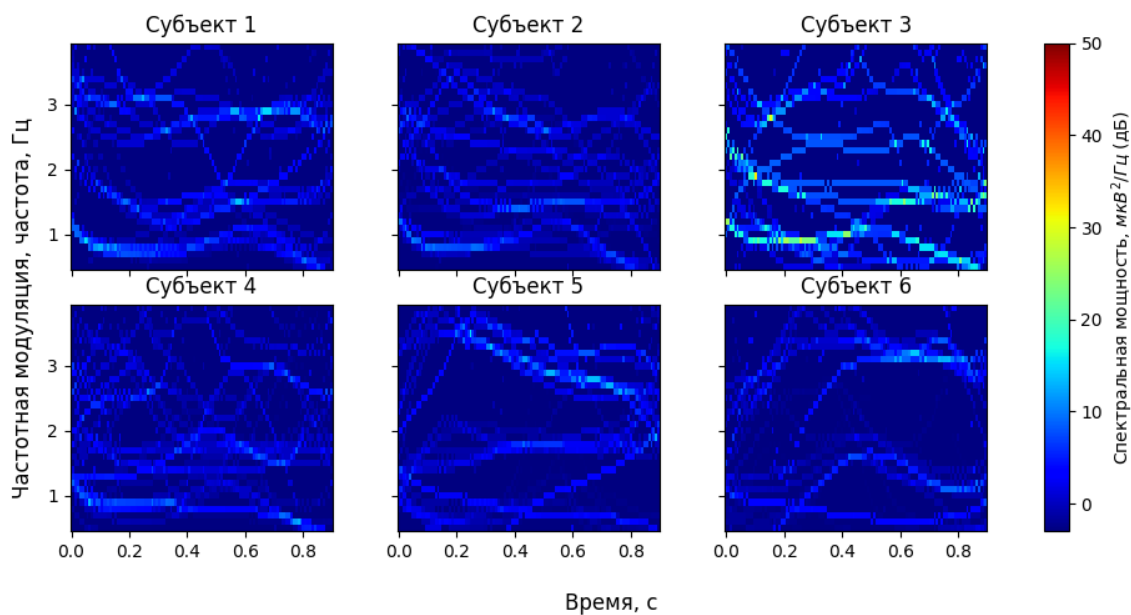


Рисунок 3.4 – Спектрограмма в области 0–4 Гц для различных субъектов

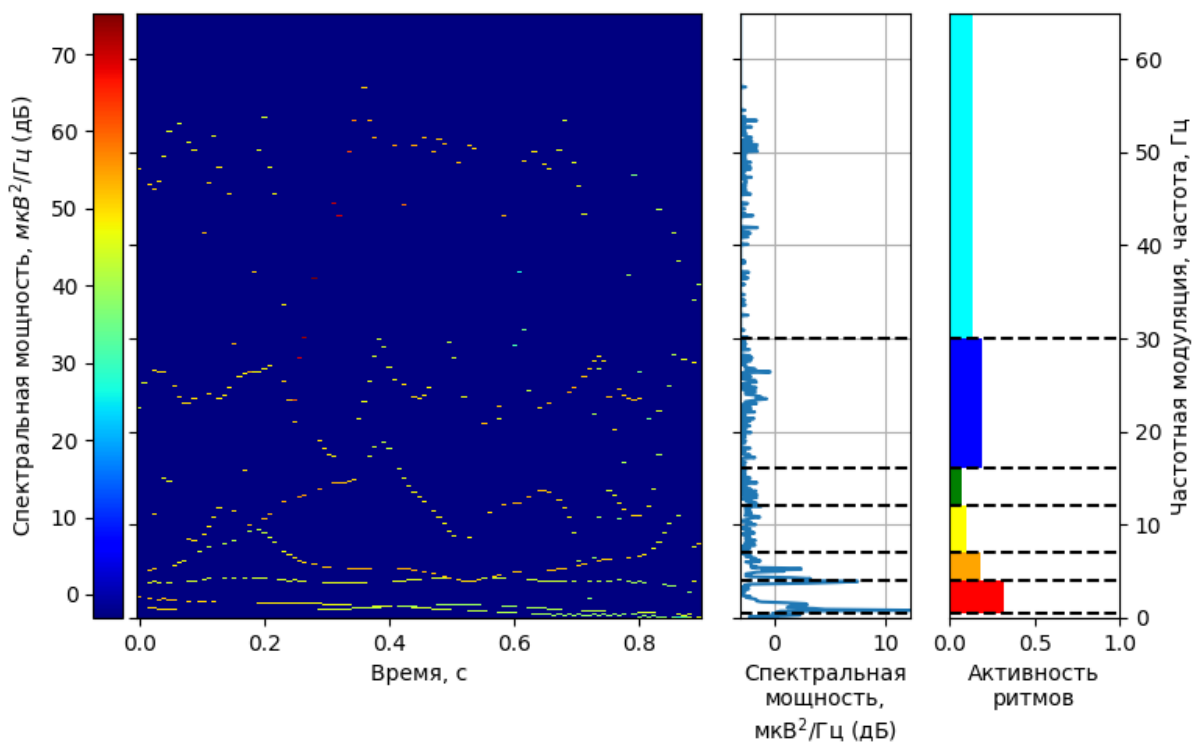


Рисунок 3.5 – Спектрограмма в области 0–60 Гц для одного из субъектов

В случае преобразования Холо-Гильберта к извлеченным мгновенным амплитудам также применяется sift для извлечения новых IMF-компонент, отражающих амплитудную модуляцию. Для этих компонент также применяется преобразование Гильберта-Хуанга, в итоге создавая многомерное представление сигнала с информацией как о частотной, так и амплитудной модуляции. В ходе

работы были сгенерированы спектрограммы, отражающие амплитудную модуляцию сигнала для всего набора данных ЭЭГ. Усредненный по всем субъектам результат представлен на Рисунке 3.6 и Рисунке 3.7.

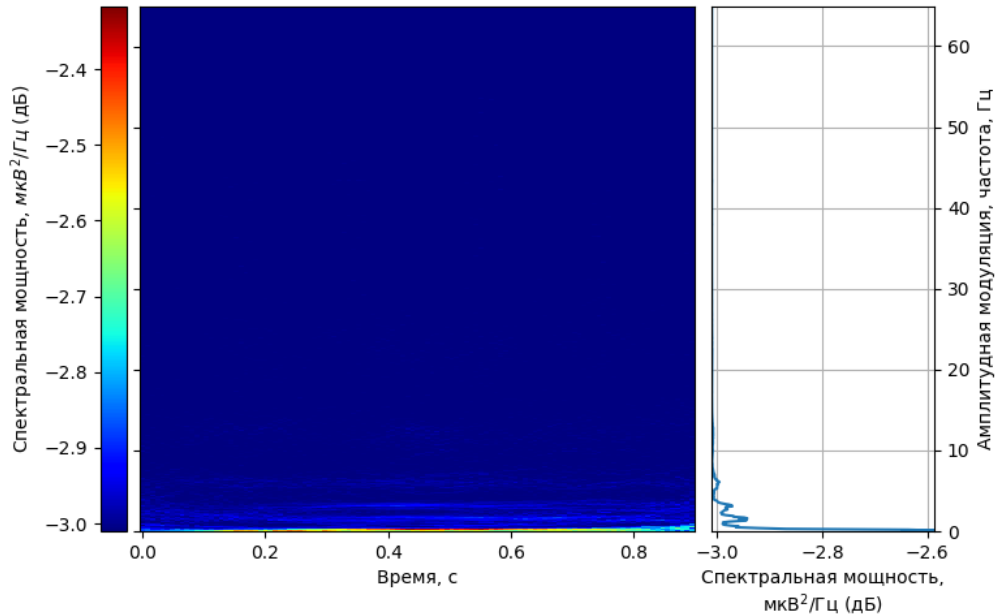


Рисунок 3.6 – Усредненная по всем каналам и эпохам субъектов спектрограмма в диапазоне 0–60 Гц, отражающая амплитудную модуляцию сигнала и полученная с помощью метода Холо-Гильберта




Рисунок 3.7. – Усредненная по всем каналам и эпохам субъектов спектрограмма в диапазоне 0–8 Гц, отражающая амплитудную модуляцию сигнала и полученная с помощью метода Холо-Гильберта

На Рисунках 3.6 и 3.7 видно наличие амплитудной модуляции сигнала ЭЭГ. Большая часть спектральной мощности также сосредоточена в области низких частот (0–8 Гц), также отражая масштабирование спектра мощности по принципу $1/f$. Для итогового процессинга данных был выделен диапазон амплитудной модуляции 0–8 Гц с 2 частотными суб-диапазонами по 4 Гц. После этого набор данных имеет следующую размерность - [8715 образцов, 64 канала, 15 FM диапазонов, 2 AM диапазона, 126 временных отсчетов].

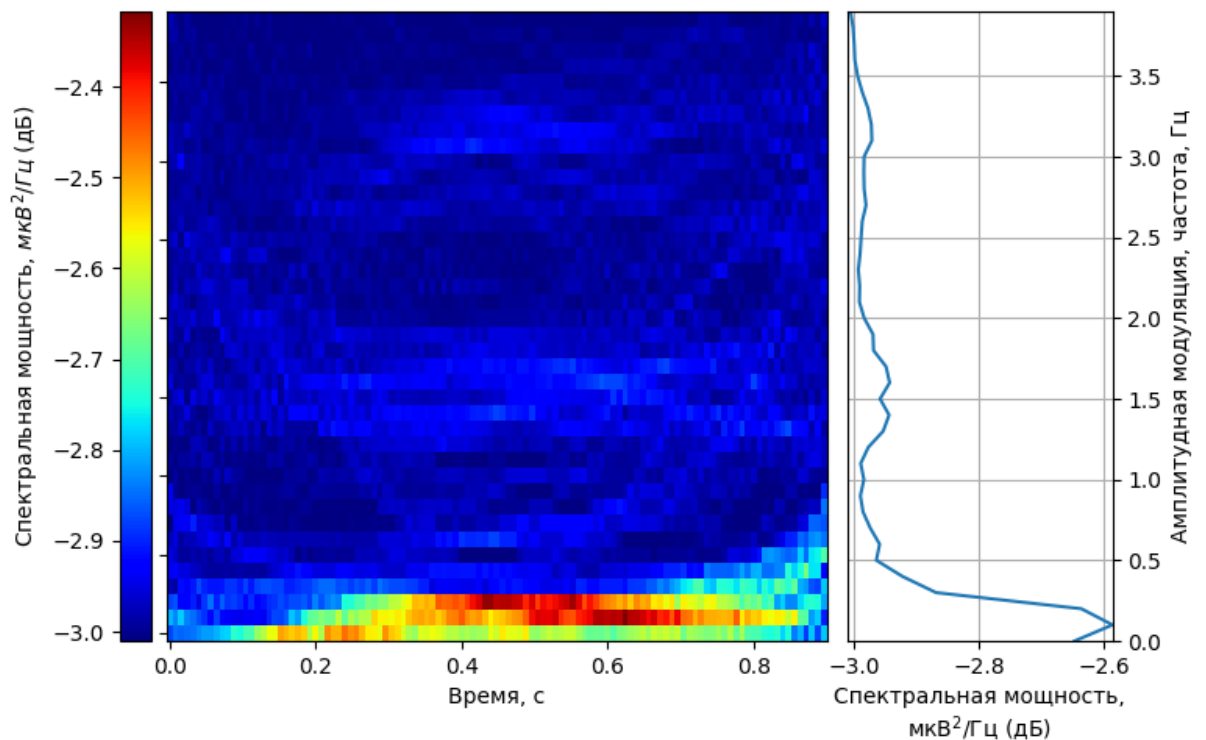


Рисунок 3.8 – Спектрограмма в области 0–4 Гц для одного из субъектов, отражающая амплитудную модуляцию сигнала и полученная с помощью метода Холо-Гильберта

В случае нечеткой системы использовалось только дискретное вейвлет преобразование для извлечения признаков. После дискретного вейвлет-преобразования набор данных имеет следующую размерность - [8715 образцов, 1152 признака]. Для оценки эффективности методов генерации структуры и отбора признаков в нечетких системах дополнительно использовались наборы данных репозитория Keel [182]. Описание этих наборов данных приведено в Таблице 3.1.

Для учета влияния краевых эффектов, искажающих спектрограммы, были исключены ~5% данных спектрограммы в начале и в конце рассматриваемого временного сегмента ЭЭГ. После этого набор данных имеет следующую размерность для преобразования Гильберта-Хуанга - [8715 образцов, 64 канала, 15 FM диапазонов, 115 временных отсчетов]. Для преобразования Холо-Гильберта размерность также скорректирована - [8715 образцов, 64 канала, 15 FM диапазонов, 2 AM диапазона, 115 временных отсчетов].

Таблица 3.1 - Описание наборов данных

Набор данных	Число классов	Число признаков	Число образцов
appendicitis	7	7	106
glass	7	9	214
haberman	2	3	306
hayes-roth	3	4	160
heart	2	13	270
ionosphere	2	33	351
iris	3	4	150
mammographic	2	5	830
newthyroid	3	5	215
penbased	10	16	10992
phoneme	2	5	5404
segment	7	19	2310
sonar	2	60	208
spectfheart	2	44	267
tae	3	5	151
wdbc	2	30	569
wine	3	13	178

В данной работе для оценки нейросетевых методов верификации используется метрика EER и доля (процент) правильной классификации. Для нечетких систем используется только доля (процент) правильной классификации. Для оценки эффективности на данных ЭЭГ в режиме верификации генерировались пары “положительных” векторов субъектов (идентификаторы субъекта для обеих векторов пары совпадают) и пары “негативных” (идентификаторы субъекта для обеих векторов пары не совпадают). В случае нечетких систем вычислялись поэлементные разницы векторов, элементы которых представляют собой признаки

на основе дискретного вейвлет преобразования. Вектор поэлементных различий векторов подавался в нечеткую систему и решалась проблема бинарной классификации. В случае метрического обучения и нейросетевого подхода в качестве метрики расстояния было выбрано косинное расстояние. Вычисленное косинное расстояние сравнивалось с пороговым значением, превышение которого означает недопуск в систему, и наоборот. Перебор пороговых значений позволяет построить кривую Detection Error Tradeoff (DET). Equal Error Rate (EER) — это место на кривой DET, где частота ошибок первого рода (False Negative Rate, TPR) равна (либо минимально различается) частоте ошибок второго рода (False Positive Rate, FPR). Чем ниже значение данного показателя, тем выше точность системы верификации. Для значения порога в точке EER также была вычислена доля правильной классификации, в случае метрического обучения. Формальные определения и постановка задачи даны в разделе 1.8.

Всего генерировалось по 5000 “положительных” векторов и по 5000 “негативных” векторов. Процесс генерации векторов различается в зависимости от выбранной схемы кросс-валидации. В работе используется два протокола валидации: обычной кросс-валидации (KFold, Рисунок 3.9) и с исключением групп (LeavePGroupsOut).

Основная проблема использования обычной кросс-валидации в случае задачи верификации заключается в том, что часть данных субъектов может попасть как обучающую, так и в тестовую выборку. Использование протокола полного исключения данных тестовых субъектов из обучающей выборке может привести к значительному снижению точности и больше подходит для оценки эффективности работы модели на неизвестных ей субъектах. В данной работе для данных ЭЭГ используется протокол LeavePGroupsOut с генерацией 20 разбиений, для данных репозитория Keel – 10-кратная KFold. В первом случае пары “положительных” векторов генерируются только для субъектов в тестовой выборке, в парах

сгенерированных “негативных” всегда присутствует субъект из тестовой выборке, а второй субъект может быть как из тестовой, так и обучающей выборки.




Рисунок 3.9 – Кросс-валидация в случае задачи верификации. Часть данных субъектов может попасть как в обучающую, так и в тестовую выборку.

3.2 Исследование эффективности построения базы правил нечеткого классификатора кластеризацией с использованием метаэвристического алгоритма “стая птиц”

В данной работе предлагается оригинальный гибридный алгоритм генерации базы правил с использованием метаэвристической кластеризации, на основе метаэвристического алгоритма “стая птиц”, описанный в разделе 2.1.4. Для его применения сначала необходимо задать необходимое число кластеров (правил нечеткой системы). Для этого на первом этапе предлагается использовать непараметрический алгоритм кластеризации Autonomous Data Partitioning (ADP). Алгоритм ADP не требует настройки гиперпараметров и автоматически создает определенное количество кластеров. Полученное число правил используется в качестве параметра k (число генерируемых центроид кластеров) для построения базы правил нечеткого классификатора кластеризацией с использованием алгоритма метаэвристического алгоритма “стая птиц”, а также алгоритма

кластеризацией с помощью k -средних и других алгоритмов кластеризации (общая схема генерации базы правил кластеризацией описана в разделе 2.1.7). На основе полученных k кластеров формируются правила нечеткой системы, полученная база правил оценивается с помощью критерия $E(data, \theta, S)$.

Для данной работы были использованы реализации алгоритмов кластеризации из пакета Python scikit-learn [182]. Из всех методов кластеризации scikit-learn в качестве аналогов были выбраны следующие:

- Minibatch k -средних (Minibatch) с параметрами по умолчанию;
- k -средних с параметрами по умолчанию.
- Агломеративная кластеризация (Aggl.) с параметрами по умолчанию;
- Спектральная кластеризация (Spectral Clustering) с параметрами по умолчанию;
- BIRCH с параметрами по умолчанию;
- OPTICS с параметрами по умолчанию.

Для сравнения эффективности количество кластеров было извлечено не только с помощью алгоритма ADP, но и с помощью алгоритмов BIRCH и OPTICS. Количество сгенерированных кластеров при использовании различных методов показано в Таблице 3.2. Два других алгоритма (BIRCH и OPTICS) генерируют слишком много или слишком мало правил и поэтому не подходят для определения количества кластеров. Все выбранные (кроме BIRCH и OPTICS) алгоритмы кластеризации требуют предварительного задания количества кластеров (в данной работе этот параметр установлен на количество кластеров, выделенных алгоритмом ADP, ADP_k в Таблице 3.2.).

Алгоритм ADP также был протестирован для генерации начальной базы правил нечеткого классификатора. В Таблице 3.3 приведены результаты метрики точности для оценки созданных баз правил, построенных различными алгоритмами, на тестовых выборках данных. Лучшие результаты на обучающем и тестовом наборах показали алгоритмы Minibatch k -means, k -means, Agglomerative Clustering, Spectral Clustering (среднее увеличение точности от 8% до 10% на

тестовой выборке). Наличие различий между методами генерации начальной базы правил нечеткого классификатора кластеризацией приведено в Таблице 3.4, Таблице 3.5, Таблице 3.6, Таблице 3.7.

Таблица 3.2 - Определенное с помощью разных алгоритмов число кластеров

Набор данных	ADP_k	$OPTICS_k$	$BIRCH_k$
appendicitis	13,40	2,40	50,00
balance	57,00	1,00	500,00
banana	12,60	262,40	13,20
bupa	21,80	2,40	118,40
glass	12,80	7,00	67,60
haberman	19,80	15,00	47,00
hayes-roth	19,80	3,20	73,20
heart	30,60	12,80	209,00
ionosphere	25,20	6,20	250,80
iris	12,60	6,40	30,80
mammographic	28,60	45,00	110,40
monk-2	48,80	4,00	345,60
newthyroid	8,80	3,60	30,60
phoneme	31,40	203,60	221,60
sonar	35,60	5,40	166,40
tae	13,80	10,40	46,60
titanic	3,80	12,40	13,80
wdbc	25,60	2,00	444,40

Таблица 3.3 - Процент правильной классификации на тестовых данных, #R – усредненные значения ранжировок, построенных отдельно по каждому из наборов

Набор данных	АЭПК	ADP ($k=ADP_k$)	Minibatch ($k=ADP_k$)	k -средних ($k=ADP_k$)	Aggl. ($k=ADP_k$)	Spectral ($k=ADP_k$)
appendicitis	72,60	87,79	83,07	86,75	84,93	84,93
balance	46,08	52,96	80,48	76,64	78,88	76,32
banana	43,68	55,04	80,92	83,06	80,36	78,43
bupa	48,41	48,41	58,26	58,55	54,20	60,00
glass	49,51	31,78	50,00	50,50	48,16	48,14
haberman	55,90	68,96	71,59	72,22	72,20	73,18
hayes-roth	40,62	38,12	41,25	40,62	49,37	41,87
heart	66,30	59,26	71,48	72,96	72,59	73,33
ionosphere	88,90	65,84	75,23	76,93	84,92	62,10
iris	94,67	69,33	94,00	95,33	91,33	91,33
mammographic	67,03	45,16	79,82	77,78	78,94	81,59
monk-2	55,55	62,73	64,35	61,59	62,95	64,36
newthyroid	95,81	75,35	92,09	91,16	91,63	85,12
phoneme	74,30	70,65	76,91	77,63	77,83	77,53
sonar	55,77	56,77	56,79	57,19	61,58	50,07
tae	35,14	35,18	54,26	50,28	53,61	55,61
titanic	67,70	67,47	77,47	77,37	77,19	77,37
wdbc	91,74	44,81	92,61	94,03	92,44	86,12
#R	4,55	5,19	2,72	2,55	2,83	3,14
Средний процентный прирост по отношению к АЭПК	-	-6,34%	8,38%	8,38%	9,08%	6,54%

Таблица 3.4 - Проверка на наличие значимых различий с помощью критерия Фридмана между результатами всех алгоритмов генерации

Нулевая гипотеза	Между результатами сопоставляемых методов имеются лишь случайные различия
Сопоставляемые методы	АЭПК, ADP ($k=ADP_k$), Minibatch ($k=ADP_k$), k -средних ($k=ADP_k$), Aggl. ($k=ADP_k$), Spectral ($k=ADP_k$)
Значение критерия теста Фридмана	31,34
Асимптотическая значимость	<0,01
Результат	Нулевая гипотеза отклоняется

Таблица 3.5 - Проверка на наличие значимых различий с помощью критерия Фридмана между результатами всех алгоритмов генерации кластеризацией

Нулевая гипотеза	Между результатами сопоставляемых методов имеются лишь случайные различия
Сопоставляемые методы	ADP ($k=ADP_k$), Minibatch ($k=ADP_k$), k -средних ($k=ADP_k$), Aggl. ($k=ADP_k$), Spectral ($k=ADP_k$)
Значение критерия теста Фридмана	24,12
Асимптотическая значимость	<0,01
Результат	Нулевая гипотеза отклоняется

Таблица 3.6 - Проверка на наличие значимых различий с помощью критерия Фридмана между результатами всех алгоритмов генерации кластеризацией за исключением ADP ($k=ADP_k$)

Нулевая гипотеза	Между результатами сопоставляемых методов имеются лишь случайные различия
Сопоставляемые методы	АЭПК, Minibatch ($k=ADP_k$), k -средних ($k=ADP_k$), Aggl. ($k=ADP_k$), Spectral ($k=ADP_k$)
Значение критерия теста Фридмана	12,86
Асимптотическая значимость	<0,05
Результат	Нулевая гипотеза отклоняется

Таблица 3.7 - Проверка на наличие значимых различий с помощью критерия Фридмана между результатами всех алгоритмов генерации кластеризацией за исключением ADP ($k=ADP_k$) и АЭПК

Нулевая гипотеза	Между результатами сопоставляемых методов имеются лишь случайные различия
Сопоставляемые методы	Minibatch ($k=ADP_k$), Kmeans ($k=ADP_k$), Aggl. ($k=ADP_k$), Spectral ($k=ADP_k$)
Значение критерия теста Фридмана	0,66
Асимптотическая значимость	0,88
Результат	Нулевая гипотеза принимается

Согласно результатам проверки в Таблице 3.4 для всего набора сопоставляемых методов существуют статистически значимые различия. При исключении алгоритма ADP статистически значимые различия сохраняются (Таблица 3.5). При исключении алгоритма АЭПК статистически значимые различия также сохраняются (Таблица 3.6). Набор методов Minibatch ($k=ADP_k$), k -средних ($k=ADP_k$), Aggl. ($k=ADP_k$), Spectral ($k=ADP_k$) не имеет статистически значимых различий, согласно Таблице 3.7.

Таким образом, алгоритм кластеризации ADP подходит только для определения числа кластеров, уступая по точности самого разбиения другим алгоритмам кластеризации. Остальные методы кластеризации, с числом кластеров определенным алгоритмом ADP, превосходят алгоритм АЭПК, но не имеют различий между собой, поэтому в дальнейшем в качестве алгоритма-аналога будет использоваться алгоритм генерации начальной базы правил нечеткого классификатора на основе алгоритма k -средних.

Выбранный алгоритм-аналог был сравнен с предложенным гибридным алгоритмом генерации базы правил с использованием метаэвристической кластеризации на основе метаэвристического алгоритма “стая птиц” (Таблица 3.8). Для гибридного алгоритма генерации отбор признаков не проводился, оптимизация параметров базы правил не проводилась, использовалась непрерывная версия метаэвристического алгоритма “стая птиц”, описанного в разделе 2.1.4, с 4-й поисковой стратегией замененной на полеты Леви и со следующими значениями параметров: размер популяции $N=40$, число итераций равно 300, $FQ=3$; $P=0,9$; $C=1,5$; $S=1,5$; $a1=1,0$; $a2=1,0$; $FL=0,75$. Предложенный гибридный алгоритм обозначен как BSA-GEN-ADPK. По результатам проверки на наличие значимых различий между результатами с помощью критерия Уилкоксона алгоритмов генерации (Таблица 3.9) было выявлено, что оригинальный гибридный алгоритм генерации базы правил с использованием метаэвристической кластеризации на основе метаэвристического алгоритма “стая птиц” превосходит оба алгоритма-аналога.

Таблица 3.8 - Процент правильной классификации на тестовых данных.

Набор данных	АЭПК	k -средних ($k=ADP_k$)	BSA-GEN-ADPK
appendicitis	72,60	86,75	87,94
balance	46,08	76,64	86,49
banana	43,68	83,06	79,88
bupa	48,41	58,55	69,28
glass	49,51	50,50	63,02
haberman	55,90	72,22	72,88
hayes-roth	40,62	40,62	59,38
heart	66,30	72,96	80,74
ionosphere	88,90	76,93	90,31
iris	94,67	95,33	97,80
mammographic	67,03	77,78	83,21
monk-2	55,55	61,59	58,37
newthyroid	95,81	91,16	94,88
phoneme	74,30	77,63	78,23
sonar	55,77	57,19	77,39
tae	35,14	50,28	58,05
titanic	67,70	77,37	76,00
wdbc	91,74	94,03	94,73
Средний процентный прирост по отношению к АЭПК	-	8,38%	14,38%

Таблица 3.9 - Проверка на наличие значимых различий между результатами с помощью критерия Уилкоксона алгоритмов генерации

Нулевая гипотеза (НГ)	Между результатами сопоставляемых методов есть лишь случайные различия		
Сопоставляемые методы	BSA-GEN-ADPK и АЭПК	BSA-GEN-ADPK и k -средних ($k=ADP_k$)	k -средних ($k=ADP_k$) и АЭПК
Значение критерия теста Уилкоксона	170,00	20,00	63,87
Асимптотическая значимость	<0,01	<0,01	<0,01
Результат	НГ отклоняется	НГ отклоняется	НГ отклоняется

3.3 Исследование эффективности отбора признаков с использованием функции трансформации и метаэвристического алгоритма “стая птиц”

Используя наборы данных из хранилища Keel был проведен отбор признаков и построение нечетких систем с помощью бинарного метаэвристического алгоритма “стая птиц” (Таблица 3.10). Генерация правил проводилась с помощью алгоритма АЭПК, оптимизация правил проводилась непрерывной версией метаэвристического алгоритма стая птиц, с замененной на полеты Леви 4-й стратегией поиска и со следующими значениями параметров: размер популяции $N=40$, число итераций равно 300, $FQ=3$; $P=0,9$; $C=1,5$; $S=1,5$; $a1=1,0$; $a2=1,0$; $FL=0,75$.

Таблица 3.10 – Результаты отбора признаков с помощью бинарного алгоритма “стая птиц” с использованием различных функций трансформации. #F - число признаков, #T - процент правильной классификации на тестовой выборке, #R – усредненные значения ранжировок, построенных отдельно по каждому из наборов.

Набор данных	Алгоритм							
	Naive		Sigm		Tanh		V	
	#T	#F	#T	#F	#T	#F	#T	#F
wine	91,02	6,80	91,56	6,40	89,32	5,60	90,97	6,60
haberman	71,23	2,00	72,53	2,20	73,18	2,00	72,23	2,00
newthyroid	91,63	3,40	92,56	3,20	95,81	3,20	94,42	3,00
appendiciti	84,89	3,40	85,80	3,80	83,12	3,00	83,94	3,20
heart	77,78	7,80	74,81	8,20	80,00	8,60	77,78	7,80
mammographic	82,14	4,60	80,42	4,40	81,20	4,40	80,01	4,20
glass	50,47	6,20	53,26	6,20	56,57	6,00	57,49	5,60
hayes-roth	58,13	1,40	59,38	1,80	61,25	2,00	58,13	1,60
iris	95,33	2,00	95,33	1,80	93,33	1,80	93,33	2,20
wdbc	93,14	10,40	94,19	9,60	95,07	10,40	95,26	10,60
penbased	48,24	14,20	54,93	14,20	52,39	13,60	49,76	13,60
sonar	72,60	29,20	82,22	29,20	74,03	24,60	69,71	26,80
ionosphere	86,89	17,20	86,34	22,60	87,76	17,00	88,89	16,60
phoneme	77,89	3,80	78,61	3,80	79,16	3,80	78,59	3,60
tae	49,59	2,20	48,37	2,40	53,66	2,40	47,63	2,00
spectfheart	76,39	13,80	74,89	11,80	79,41	13,80	76,00	12,40
segment	60,43	8,80	62,16	8,80	62,55	8,40	63,94	7,60
#R:	2,97	2,97	2,44	2,88	1,91	2,32	2,67	1,82

Полученные результаты исследованы с помощью критерия Фридмана. По числу признаков ($\#F$) результаты статистически различимы (Таблица 3.11), по проценту правильной классификации на тестовой выборке ($\#T$) результаты неразличимы (Таблица 3.12). Таким образом, на рассмотренных наборах данных способы отбора показали различия по числу отобранных признаков при неразличимых результатах по проценту правильной классификации на тестовой выборке. Наилучший результат показали Tanh и V функции трансформации.

Таблица 3.11 - Проверка на наличие значимых различий с помощью критерия Фридмана между результатами отбора признаков с использованием различных функций трансформации по метрике точности правильной классификации на тестовой выборке

Нулевая гипотеза	Между результатами сопоставляемых методов имеются лишь случайные различия
Значение критерия теста Фридмана	4,12
Асимптотическая значимость	0,25
Результат	Нулевая гипотеза принимается

Таблица 3.12 - Проверка на наличие значимых различий с помощью критерия Фридмана между результатами отбора признаков с использованием различных функций трансформации числу отобранных признаков

Нулевая гипотеза	Между результатами сопоставляемых методов имеются лишь случайные различия
Значение критерия теста Фридмана	12,02
Асимптотическая значимость	<0,01
Результат	Нулевая гипотеза отвергается

3.4 Проверка предложенных алгоритмов отбора признаков и генерации структуры нечеткого классификатора для набора данных ЭЭГ и решения задачи верификации

Предложенные алгоритмы построения нечеткого классификатора в последствии применены для набора данных ЭЭГ PEEGMMID. После извлечения признаков имеем следующую размерность набора данных - [8715 образцов, 1152 признаков]. Использовался протокол валидации LeavePGroupsOut ($P=20$, 20 итераций валидации). Препроцессинг данных и протоколы валидации описаны более подробно в разделе 3.1.

В качестве модели-аналога использовались модель машинного обучения LinearSVC, дерево решений (DecisionTreeClassifier) и ансамбль (RandomForestClassifier) деревьев решений из пакета scikit-learn для сравнения с нечетким классификатором. Для варианта BSA-GEN оптимизация правил проводилась непрерывной версией метаэвристического алгоритма “стая птиц”, с замененной на полеты Леви 4-й стратегией поиска и со следующими значениями параметров: размер популяции $N=40$, числом итераций равным 500, $FQ=3$; $P=0,9$; $C=1,5$; $S=1,5$; $a1=1,0$; $a2=1,0$; $FL=0,75$. Аналогичные параметры были установлены для бинарного метаэвристического алгоритма “стая птиц”, за исключением числа итераций, равного 1000. Число правил для алгоритмов генерации правил кластеризацией было определено с помощью алгоритма ADP ($ADP_k=20$). Все варианты построения нечеткого классификатора описан в Таблице 3.13. Для LinearSVC, деревьев решений (одиночных и ансамбля) отбор признаков проводился с помощью метода-фильтра на основе взаимной информации.

По результатам в Таблице 3.14 лучшим по точности классификации является алгоритм на основе метаэвристической кластеризации. Он не только превосходит классификатор на основе машины опорных векторов с линейным ядром по точности, но и более интерпретируем. У нечеткого классификатора меньше правил и схожее число признаков, по сравнению с деревьями

решений, однако большое число признаков все еще затрудняет возможности интерпретации.

Таблица 3.13 - Перечень вариантов построения нечеткого классификатора

Обозначение	Генерация	R	Отбор признаков	Оптимизация термов
EX-BS	АЭПК	2	бинарный алгоритм “стая птиц” с функцией трансформации V	Непрерывный алгоритм “стая птиц”
ADP-KMEANS	k -средних ($k=ADP_k$)	20	бинарный алгоритм “стая птиц” с функцией трансформации V	Непрерывный алгоритм “стая птиц”
BSA-GEN	BSA-GEN-ADPK	20	бинарный алгоритм “стая птиц” с функцией трансформации V	Непрерывный алгоритм “стая птиц”

Таблица 3.14 - Результаты построения классификаторов на наборе данных ЭЭГ

Обозначение	R	Число признаков	Процент правильной классификации
EX-BS	2	93	75,94
ADP-KMEANS	20	90	83,70
BSA-GEN	20	98	85,31
LinearSVC	-	75	78,85
Дерево решений	70 правил	81	74,32
Ансамбль деревьев	100 ансамблей по 60 правил	79	78,59

Таблица 3.15 – Проверка наличия статистически значимых различий между моделями по критерию Уилкоксона

Нулевая гипотеза (H ₀)	Между результатами сопоставляемых методов имеются лишь случайные различия	
Методы	BSA-GEN и ADP-KMEANS	BSA-GEN и LinearSVC
Значение критерия	202,00	209,00
Асимптот. Значимость	<0,01	<0,01
Результат	H ₀ отклоняется	H ₀ отклоняется

3.5 Проверка эффективности верификации субъекта на основе данных электроэнцефалограммы с использованием извлечения признаков на основе преобразования Холо-Гильберта и метрического обучения

В Таблице 3.16 приведены обозначения проверяемых вариантов моделей, используемых признаков и протоколов валидации. Для реализации моделей использовался фреймворк PyTorch [183] и пакет pytorch-metric-learning [184]. Для метрического обучения использовалась функция потерь Multi-Similarity Loss. Средние значения метрик (ошибка EER и процент правильной классификации) приведены в Таблице 3.17, полные данные о значениях метрик на каждой из итераций валидации приведены в Приложении А. По результатам проверки эффективности были проведены попарные сравнения по критерию Уилкоксона.

Таблица 3.16 - Обозначения проверяемых вариантов моделей, используемых признаков и протоколов валидации

Обозначение	Раздел описания	Используемые признаки или преобразования	Протокол валидации	Число итераций обучения	Размер батча
DWT	Раздел 2.3.1	Коэффициенты дискретного вейвлет преобразование, извлеченных по схеме, описанной в разделе 2.1.2	LeavePGroupsOut	100	512
1DCNN-Hilbert-KF	Раздел 2.3.2	Преобразование Гильберта-Хуанга по схеме, описанной в разделе 3.1.	Кросс-валидация KFold	20	512
1DCNN-Hilbert	Раздел 2.3.2	Преобразование Гильберта-Хуанга по схеме, описанной в разделе 3.1.	LeavePGroupsOut	20	512
2DCNN-Hilbert	Раздел 2.3.2	Преобразование Гильберта-Хуанга по схеме, описанной в разделе 3.1.	LeavePGroupsOut	20	512
1DCNN-Holo	Раздел 2.3.3	Преобразование Холо-Гильберта по схеме, описанной в разделе 3.1.	LeavePGroupsOut	20	512
3DCNN-Holo	Раздел 2.3.3	Преобразование Холо-Гильберта по схеме, описанной в разделе 3.1.	LeavePGroupsOut	20	512

Таблица 3.17 - Обозначения проверяемых вариантов моделей, используемых признаков и протоколов валидации

Архитектура	Процент правильной классификации	EER
1DCNN-Hilbert-KF	97,59	2,42
1DCNN-Hilbert	89,02	10,92
2DCNN-Holo	85,37	14,62
1DCNN-Holo	89,83	9,95
3DCNN-Holo	87,00	12,98
DWT	80,09	19,33

Для проверки двух протоколов валидации, LeavePGroupsOut и KFold, описанных в разделе 3.1, была выбрана архитектура 1DCNN-Hilbert. По проверки наличия статистически значимых различий между протоколами валидации для архитектуры на основе преобразования Гильберта-Хуанга по метрике EER с помощью критерия Уилкоксона (Таблица 3.18) была выявлена значимая статистическая разница. Таким образом, подтверждено, что полное исключение субъектов тестовой выборки из обучающей значительно снижает точность верификации системы. Протокол LeavePGroupsOut был выбран для дальнейших сравнений, как более полно отражающий условия работы системы верификации в реальном мире.

Таблица 3.18 - Проверка наличия статистически значимых различий между протоколами валидации для архитектуры на основе преобразования Гильберта-Хуанга по метрике EER с помощью критерия Уилкоксона

Нулевая гипотеза	Между результатами сопоставляемых методов имеются лишь случайные различия
Сопоставляемые методы	1DCNN- Hilbert и 1DCNN- Hilbert-KF
Значение критерия теста Уилкоксона	0,1092
Асимптотическая значимость	<0,01
Результат	Нулевая гипотеза отклоняется

Проведено сравнение двух архитектур на основе преобразования Гильберта-Хуанга, одна из которых рассматривает спектрограмму как двумерное изображение, а другая – как совокупность временных рядов значений спектральной мощности, каждый из которых соответствует определенному частотному диапазону. Результаты приведены в Таблице 3.19 и показывают превосходство архитектуры на основе одномерных сверток. Аналогичное сравнение проведено для архитектур на основе преобразования Холо-Гильберта, в этом случае сравнивается спектральное 3-мерное представление сигнала с его декомпозицией на временные ряды, где каждое значение соответствует паре определенных частотных диапазонов частотной и амплитудной модуляции. Результаты проверки по критерию Уилкоксона также приведены в Таблице 3.20 и тоже показывают превосходство архитектур на основе одномерных сверток.

Таблица 3.19 - Проверка наличия статистически значимых различий между архитектурами на основе преобразования Гильберта-Хуанга по метрике EER с помощью критерия Уилкоксона

Нулевая гипотеза	Между результатами сопоставляемых методов имеются лишь случайные различия
Сопоставляемые методы	1DCNN- Hilbert и 2DCNN-Hilbert
Значение критерия теста Уилкоксона	209.00
Асимптотическая значимость	<0,01
Результат	Нулевая гипотеза отклоняется

В Таблице 3.21 приведены результаты проверки наличия статистически значимых различий между одномерными архитектурами на основе преобразования Гильберта-Хуанга и Холо-Гильберта. Результаты показывают наличие значимых различий, что свидетельствует о повышении точности верификации при включении информации об амплитудной модуляции сигнала ЭЭГ.

Таблица 3.20 - Проверка наличия статистически значимых различий между архитектурами на основе преобразования Холо-Гильберта по метрике EER с помощью критерия Уилкоксона

Нулевая гипотеза	Между результатами сопоставляемых методов имеются лишь случайные различия
Сопоставляемые методы	1DCNN- Holo и 3DCNN-Holo
Значение критерия теста Уилкоксона	210,0
Асимптотическая значимость	<0,01
Результат	Нулевая гипотеза отклоняется

Таблица 3.21 Проверка наличия статистически значимых различий между архитектурами на основе преобразования Гильберта-Хуанга и Холо-Гильберта по метрике EER с помощью критерия Уилкоксона

Нулевая гипотеза	Между результатами сопоставляемых методов имеются лишь случайные различия
Сопоставляемые методы	1DCNN- Holo и 1DCNN-Hilbert
Значение критерия теста Уилкоксона	182,5
Асимптотическая значимость	<0,01
Результат	Нулевая гипотеза отклоняется

Заключительная проверка проводилась на наличие разницы между одномерной архитектурой на основе преобразования Холо-Гильберта и многослойным перцептроном, оперирующего признаками на основе дискретного вейвлет-преобразования (Таблица 3.22). Таким образом, наилучшим образом при решении задачи верификации на основе данных ЭЭГ показывает себя архитектура на основе преобразования Холо-Гильберта и одномерных сверток, с итоговым значением метрики EER равным 9,95%.

Таблица 3.22 Проверка наличия статистически значимых различий между архитектурами на основе дискретного-вейвлет преобразования и на основе преобразования Холо-Гильберта по метрике EER с помощью критерия Уилкоксона

Нулевая гипотеза	Между результатами сопоставляемых методов имеются лишь случайные различия
Сопоставляемые методы	1DCNN- Holo и DWT
Значение критерия теста Уилкоксона	210.0
Асимптотическая значимость	<0,01
Результат	Нулевая гипотеза отклоняется

3.6 Выводы

1. Для подтверждения эффективности предложенного комплексного алгоритма построения базы правил нечеткого классификатора, особенностью которого является использование кластеризации на основе метаэвристического алгоритма “стая птиц” был проведен эксперимент построения соответствующих нечетких классификаторов на 18 наборах данных репозитория Keel. Для определения числа кластеров используется алгоритм Autonomous Data Partitioning. Предложенный алгоритм превзошел по точности правильной классификации алгоритмы-аналоги АЭПК (прирост 14,38% правильной классификации) и построения базы правил нечеткого классификатора с использованием кластеризации k -means (прирост 6,00% правильной классификации), разница статистически значима ($p < 0,01$).

2. Разработан алгоритм отбора признаков, особенностью которого является использование функции трансформации и метаэвристического алгоритма “стая птиц”. Предложенный алгоритм ориентирован на улучшение точности нечеткого классификатора путем снижения числа признаков и уменьшения поискового пространства. Полученные результаты исследованы с помощью критерия Фридмана. По числу признаков результаты статистически различимы, по проценту правильной классификации на тестовой выборке

результаты неразличимы. Таким образом, на рассмотренных наборах данных способы отбора показали различия по числу отобранных признаков при неразличимых результатах по проценту правильной классификации на тестовой выборке. Наилучший результат показали Tanh и V-образная функции трансформации. Предложенный гибридный алгоритм построения базы правил нечеткого классификатора, особенностью которого является использование кластеризации на основе метаэвристического алгоритма “стая птиц”, и алгоритм отбора признаков, особенностью которого является использование V-образной функции трансформации и метаэвристического алгоритма “стая птиц”, применены для решения задачи верификации на основе данных ЭЭГ Physionet. Нечеткий классификатор, построенный на основе предлагаемых методов, превосходит классификатор на основе машины опорных векторов с линейным ядром (прирост 6,46% правильной классификации) и нечеткий классификатор на основе АЭПК (прирост 9,37% правильной классификации) по точности. Полученный нечеткий классификатор более интерпретируем, чем классификатор на основе машины опорных векторов, однако большое число признаков и правил все еще затрудняют возможности интерпретации.

3. По результатам эксперимента оригинальный метод верификации субъекта на основе данных, отличительной особенностью которого является использование извлечения признаков с помощью преобразования Холо-Гильберта и метрического обучения, показал статистически значимое снижение ошибки верификации по сравнению с архитектурой на основе дискретного вейвлет-преобразования (снижение на 9,38% метрики ошибки EER) и преобразования Гильберта-Хуанга (снижение на 0,97% метрики ошибки EER). Также показано статистически значимое снижение ошибки верификации при использовании архитектур на основе одномерных сверток на результатах преобразования Гильберта-Хуанга и Холо-Гильберта. Для двух протоколов валидации, LeavePGroupsOut и KFold, выявлены статистически значимые различия между протоколами валидации для архитектуры на основе

одномерных сверток и подтверждено, что полное исключение субъектов тестовой выборки из обучающей значительно повышает значение ошибки верификации системы. Протокол `LeavePGroupsOut` выбран для применения, как более полно отражающий условия работы системы верификации в реальном мире.

Глава 4. Применение предложенных методов для решения задачи классификации сегментов ЭЭГ и выявления эпилептиформ

4.1 Задача классификации сегментов ЭЭГ и выявления эпилептиформ

ЭЭГ является основным методом, с помощью которого неврологи диагностируют заболевания, связанные с головным мозгом, такие как эпилепсия и судороги [186-187]. Около 50 млн человек в мире страдают эпилепсией, которая является наиболее распространенным заболеванием головного мозга [188]. Она характеризуется внезапными и повторяющимися припадками, возникающими в результате чрезмерного и синхронного электрического разряда большого числа нейронов. По клиническим проявлениям эпилептические припадки можно разделить на два основных класса - парциальные и генерализованные [189]. Парциальные, или фокальные, эпилептические припадки затрагивают лишь ограниченный участок мозга (эпилептический очаг) и остаются ограниченными этой областью, в то время как генерализованные эпилептические припадки охватывают практически весь мозг. Оба класса эпилептических припадков могут возникать в любом возрасте. Эпилептиформная активность в сигналах ЭЭГ, включая спайки, острые волны или комплексы спайк-волна, может проявляться не только во время припадка (иктальный период), но и за некоторое время до припадка (преиктальный период) и между припадками (межприпадочный период). В связи с этим сигналы ЭЭГ чаще всего используются для клинической оценки состояния мозга, включая как прогнозирование, так и выявление эпилептических припадков [190-193]. Однако выявление эпилептиформной активности в ЭЭГ-сигналах путем визуального сканирования записей ЭЭГ, которые обычно собираются в течение нескольких дней, является утомительным и тяжелым, так как эпилептиформы легко спутать с активностью человека – моргание, движения глаз, тела также отражаются на ЭЭГ. Поэтому, совместно с сотрудниками неврологического отделения Томского НИИ Курортологии и физиотерапии

ФМБА России (ТНИИКФ) решалась задача автоматизации процесса обнаружения эпилептиформ (Рисунок 4.1) на сегментах ЭЭГ.




Рисунок 4.1 – Примеры эпилептиформ из [191]

4.2 Сбор набора данных и решение задачи с помощью нечетких классификаторов

Для решения задачи на основе нечетких классификаторов был собран собственный набор данных на основе базы данных неврологического отделения ТНИИКФ. Из заключений были извлечены те, в которых упоминалось выявление эпилептиформной активности, на соответствующих записях в проприетарной программе просмотра и анализа ЭЭГ по заключениям выделены сегменты эпилептиформной и нормальной активности. Данные ЭЭГ в неврологическом отделении снимаются при помощи аппарата «Энцефалан-ЭЭГР-19/26» производства компании Медиком. Данный прибор снимает данные с 26 каналов ЭЭГ, также поддерживая синхронную запись данных ЭКГ. «Энцефалан-ЭЭГР-19/26» поставляется вместе с проприетарным программным обеспечением и хранит данные в закрытом формате, не являющимся форматом edf. В связи с этим было решено использовать в качестве признаков числовые показатели,

рассчитываемые ПО «Энцефалан-ЭЭГР-19/26» (Рисунок 4.2) для выделенных сегментов ЭЭГ. Среди них:

1) абсолютные значения мощностей отдельно для каждого из каналов снятия ЭЭГ и набора ритмов ЭЭГ (Дельта1 (суб-диапазон Дельта ритма), Дельта2, Тета, Альфа, Бета1, Бета2) и значения абсолютной мощности, просуммированные по каналам отдельно для каждого диапазона, мкВ^2 ;

2) относительные значения мощностей отдельно для каждого из каналов снятия ЭЭГ и набора ритмов ЭЭГ и значения, усредненные по каналам отдельно для каждого диапазона, %;

3) значения доминирующих частот отдельно для каждого из каналов снятия ЭЭГ и набора ритмов ЭЭГ и значения, усредненные по каналам отдельно для каждого диапазона, %;

4) значения средневзвешенных частот отдельно для каждой из каналов снятия ЭЭГ и набора ритмов ЭЭГ (Дельта1 (суб-диапазон Дельта ритма), Дельта2, Тета, Альфа, Бета1, Бета2) и значения, усредненные по каналам отдельно для каждого диапазона, %;

5) значения относительного коэффициента асимметрии для каждой из predetermined набора пар датчиков (Fp1-Fp2, F7-F8, F3-F4, T3-T4, C3-C4, T5-T6, P3-P4, O1-O2) и набора ритмов ЭЭГ, а также значения, усредненные по парам датчиков отдельно для каждого диапазона, %;

6) значения коэффициента частотной асимметрии для каждой из predetermined набора пар датчиков (Fp1-Fp2, F7-F8, F3-F4, T3-T4, C3-C4, T5-T6, P3-P4, O1-O2) и набора ритмов ЭЭГ, а также значения, усредненные по парам датчиков отдельно для каждого диапазона, %;

7) значения абсолютного коэффициента асимметрии для каждой из predetermined набора пар датчиков (Fp1-Fp2, F7-F8, F3-F4, T3-T4, C3-C4, T5-T6, P3-P4, O1-O2) и набора ритмов ЭЭГ, а также значения, усредненные по парам датчиков отдельно для каждого диапазона и средние значения по всем диапазонам ритмов отдельно для каждой из пар датчиков, %.

Всего были собраны данные 30 пациентов. На записях пациентов с эпилептиформной активностью зачастую присутствуют сразу несколько эпилептиформ. За счет этого получилось выделить 48 сегментов: 25 нормальных сегментов и 23 с эпилептиформами. Сегменты варьируются по длине, для каждой извлечены вышеуказанные признаки, всего таких признаков – 1029. Полученный набор данных имеет следующую размерность – [48 сегментов, 1029 признаков].




Рисунок 4.2 - «Энцефалан-ЭЭГР-19/26»

На Рисунке 4.3 приведен пример заключения, на основании которых искались эпилептиформы:

Общая характеристика ЭЭГ в покое:

ФОН:

Доминирует умеренно дезорганизованная альфа-активность в виде ритма высокой амплитуды (до 69 мкВ), среднего индекса (до 67 %), недостаточно регулярная (с разбросом частот 7.6-9.4 Гц), с преобладанием заостренных волн, с областью выраженности в затылочной области (О1 О2). Модуляции по амплитуде хорошо выражены, зональные различия сохранены.

Бета-активность в виде ритма высокого индекса (до 81%), средней амплитуды (до 21 мкВ), высокой частоты, наиболее выраженная в левой лобной области (F3). (Возможно присутствие МИОГРАММЫ!)

Медленная активность среднего индекса с амплитудой до 54 мкВ в виде групп волн.

Реакция активации:

При ОГ - четкая депрессия альфа ритма. ЗГ - альфа ритм восстановился полностью.

Изменение ЭЭГ при провоцирующих ФП:

ФТЗ-15 :

Дельта активность: повысилась до значимой; максимальная выраженность в левой лобной области (F3).

ГВ1 :

Регистрируется единичный комплекс спайк-медленная волна амплитудой до 300мкВ диффузно с преобладанием в левых лобных отведениях.

Тета активность: амплитуда ритма увеличилась с 54мкВ до 124мкВ; индекс увеличился на 17%; максимальная выраженность в левой лобной и затылочно-теменной областям (F3 О2 О1 P3). Дельта

активность: повысилась до значимой; максимальная выраженность в затылочной и левой лобной областям (О2 О1 F3).

ЗАКЛЮЧЕНИЕ:

ОБЩАЯ ОЦЕНКА: ЭЭГ соответствует возрасту. На фоне 1-ой минуты ГВ регистрируется единичный комплекс спайк-медленная волна амплитудой до 300 мкВ диффузно с преобладанием в лобных областях слева. Умеренные изменения ЭЭГ регуляторного характера.

Рек-но: консультация эпилептолога, контроль ЭЭГ в динамике.

Рисунок 4.3 – Пример заключения

В процессе формирования набора все данные были обезличены. Пример собранных данных приведен в Приложении Б.

На основе собранных данных решалась задача бинарной классификации – наличия, либо отсутствия эпилептиформы, без определения конкретного класса, к которому может принадлежать эпилептиформа. Были построены несколько моделей на основе собранных данных – классификатор на основе машины опорных векторов (LinearSVC), XGBClassifier [194], дерево решений, логистическая регрессия, случайный лес (Random Forest, RF), Catboost [195] и предложенный в диссертационной работе алгоритм отбора признаков на основе V-образной трансформационной функции и бинарного метаэвристического алгоритма “стая птиц” с замененной на полеты Леви 4-й стратегией поиска и со следующими значениями параметров: размер

популяции $N=40$; число итераций равно 300; $FQ=3$; $P=0,9$; $C=1,5$; $S=1,5$; $a1=1,0$; $a2=1,0$; $FL=0,75$. Для генерации базы правил был выбран алгоритм АЭПК, так как образцов данных слишком мало для приемлемого качества кластеризации. Значения признаков преобразовывались с помощью z-нормализации, проводилась 10-кратная кросс-валидация, усредненные результаты приведены в Таблице 4.1.

Таблица 4.1 – Точность классификации на тестовой выборке

Модель	Процент правильной классификации на тестовой выборке, %
LinearSVC	82,50%
XGBClassifier	66,00%
Дерево решений	62,50%
Логистическая регрессия	82,50%
Catboost	76,50%
RF	76,50%
BSO-GEN-V	84,40%

Наилучшую точность показала модель на основе нечеткого классификатора, а также классификатор на основе машины опорных векторов и логистическая регрессия.

Итоговый нечеткий классификатор был построен на всех данных без разбиения на обучающую и тестовую выборки, в итоге отобрав следующие признаки: суммарное относительное значение мощности для O2-A2, абсолютный коэффициент асимметрии ритма Бета2 для Fr1-Fr2, суммарное относительное значение мощности для O1-A1, относительное значение мощности для Альфа-ритма P4-A2, абсолютный коэффициент асимметрии

ритма Бета2 для Т3-Т4, относительное значение мощности для ритма Бета2 и F4-A2, относительное значение мощности для ритма Бета2 и Fp2-A2, значение доминирующих частот для Альфа-ритма и P4-A2, значение доминирующих частот Альфа-ритма, P3-A1. На основе построенного нечеткого классификатора было построено веб-приложение в фреймворке Gradio [195]. Интерфейс приложения приведен на Рисунке 4.4.

Обнаружение эпилептиформ на сегментах ЭЭГ на основе признаков с помощью нечеткого классификатора

Входные данные

Отн. знач. мощностей, %, сумма, O2-A2	Абс. коэф. ассим. %, Бета2, Fp1-Fp2	Отн. знач. мощн. %, сумма, O1-A1	Отн. знач. мощн. %, Альфа, P4-A2	Абс. коэф. ассим. %, Бета2, Т3-Т4	Отн. знач. мощн. %, Бета2, F4-A2	Отн. знач. мощн. %, Бета2, Fp2-A2
97.23	-49.24	95.95	187.6	-67.73	2.41	2.44
99	-7.64	98.59	13.23	16.44	2.44	0.78
98.55	-46.9	93.98	276.08	-56.24	1.48	2.09
97.82	-26.84	95.51	351.38	-64.31	0.77	0.95
97.26	-75.14	89.88	80.97	-91.16	0.8	0.92
97.69	0.53	98.02	75.92	10.36	6.63	7.59
94.54	40.19	95.79	37.66	35.95	9.16	9.49
96.86	37.26	97.55	62.48	34.87	8.19	9.66
99.09	-51.25	98.94	87.78	-42.77	2.29	2.27
96.56	-18.47	93.61	39.69	-57.22	2.64	2.96

New row

Clear Submit

Examples

97.23	-49.24	95.95	-
99	-7.64	98.59	-
98.55	-46.9	93.98	-

Заполните значения признаков в таблице соответствующими значениями спектральных характеристик из программы просмотра записи ЭЭГ, предварительно выделив сегмент. После заполнения нажмите кнопку Submit. В правой таблице будет представлен результат классификации - наличие/отсутствие эпилептиформы либо сообщение об ошибке во входных данных. Для тестирования уже готовых примеров нажмите Examples.

Use via API - Built with Gradio

Предсказания

Наличие эпилептиформ	Активация правил
Есть эпилептиформы	[[4.34475473e-36] [1.99196221e-20]]
Есть эпилептиформы	[[2.66067582e-66] [1.51817421e-37]]
Есть эпилептиформы	[[3.03514089e-52] [2.04855464e-06]]
Есть эпилептиформы	[[1.47777601e-69] [5.26970915e-08]]
Есть эпилептиформы	[[1.20636712e-97] [2.13386199e-52]]
Нет эпилептиформ	[[3.03103354e-18] [2.39185738e-19]]
Нет эпилептиформ	[[4.25398453e-20] [7.94049634e-36]]
Нет эпилептиформ	[[1.02815059e-35] [1.66910187e-36]]
Нет эпилептиформ	[[1.27916447e-22] [2.07915251e-37]]
Нет эпилептиформ	[[1.64308981e-20] [6.77778135e-21]]

Рисунок 4.4 – Интерфейс веб-приложения

4.3 Решение задачи с помощью моделей на основе преобразования Холло-Гильберта

Так как предыдущее решение требует от врача ручного ввода данных признаков сегмента, а этих сегментов может быть множество и невозможно автоматизировать процесс ввода признаков из-за проприетарного формата хранения данных ЭЭГ, было принято решение построить альтернативную модель на стороннем наборе данных эпилептиформ ЭЭГ. Для этой цели выбран набор данных TUN EEG Event Corpus [197]. TUN EEG — это крупнейшая в мире общедоступная база клинических ЭЭГ-данных,

включающая более 28 тыс. записей ЭЭГ, принадлежащих более 15 тыс. пациентов. Она представляет собой коллективный результат работы отделения неврологии госпиталя университета Temple с 2002 года, является действующим и сейчас проектом по сбору данных. Сигналы ЭЭГ регистрировались с помощью нескольких поколений технологии записи ЭЭГ оборудования Nicolet™ компании Natus Medical Incorporated. Исходные сигналы, полученные в ходе исследований, представляют собой многоканальные записи, включающие от 20 до 128 каналов с частотой дискретизации не менее 250 Гц с использованием 16-разрядного АЦП. Данные хранятся в собственном формате, который экспортируется в EDF с помощью программы NicVue v5.71.4.2530. В данной работе все данные были приведены к общей частоте дискретизации 125 Гц.

В наборе данных квалифицированными специалистами-эпилептологами были выделены сегменты и каналы с проявлениями трех видов эпилептиформных событий:

- 1) спайки и/или острые волны (Spike Slow Wave, SPSW)
- 2) периодические латерализованные эпилептиформные разряды (Periodic Lateralized Epileptiform Discharges, PLED);
- 3) обобщенные периодические эпилептиформные разряды (Generalized Lateralized Epileptiform Discharges, GPED).

SPSW представляют собой эпилептиформные переходные процессы, которые обычно наблюдаются у пациентов с эпилепсией. PLED свидетельствуют об аномалиях ЭЭГ и часто проявляются в виде повторяющихся спайковых или островолновых разрядов, которые могут быть фокальными или латерализованными в одном полушарии. Эти сигналы имеют квазипериодический характер. GPED сходны с PLED и проявляются в виде периодических коротко интервальных диффузных разрядов, периодических длинно интервальных диффузных разрядов и паттернов подавления-всплеска в зависимости от интервала между разрядами. К этому классу также относятся

трифазные волны, проявляющиеся в виде диффузных и билатерально синхронных шипиков с бифронтальным преобладанием, частота которых обычно составляет 1–2 Гц.

В наборе данных также присутствуют иные классы сегментов без присутствия эпилептиформ:

1) артефакты (ARTF) — это зарегистрированная электрическая активность, не имеющая мозгового происхождения, например, вызванная оборудованием, поведением пациента или окружающей средой;

2) движения глаз (EYEM) – события движений глаз, которые часто можно спутать со спайком;

3) фон (BCKG) – обычный сегмент записи ЭЭГ без артефактов и какой-либо аномальной активности.

В Таблице 4.2 приведено соотношение классов, где наблюдается достаточно большой дисбаланс. На Рисунке 4.5 и Рисунке 4.6 приведены примеры рассматриваемых классов.

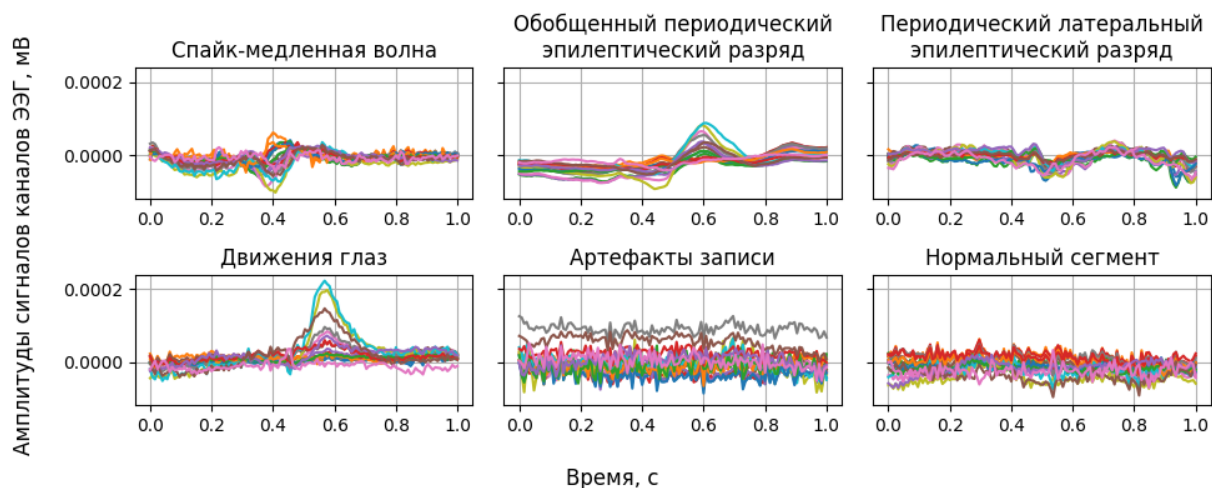


Рисунок 4.5 – Пример рассматриваемых классов без усреднения по каналам

На основании уже существующих работ по классификации наличия эпилептиформной активности [198] сделан вывод о достаточно низкой точности при решении 6-классовой задачи (конкретной использованной метрики в работе [198] не указано, вывод делался на относительном соотношении неизвестной метрики оценки, а в работе для сравнения

использовались другие модели-аналоги), наилучшая точность достигается при группировке классов SPSW, GPED, PLED в один класс и EYEM, ARTF, BCKG во второй и решении задачи бинарной классификации. Соотношение полученных классов получается достаточно сбалансированным (4228 образцов 1-го класса и 5061 2-го класса в обучающей выборке, 1402 образца 1-го класса и 1709 2-го класса в обучающей выборке). Незначительную часть данных (16 сегментов) не удалось считать из-за ошибок в данных.




Рисунок 4.6 – Пример рассматриваемых классов с усреднением по каналам

Данные набора предоставляются с уже готовым разбиением на обучающую и тестовую выборки, без пересечения субъектов записи (данные субъектов в тестовой выборке не присутствуют в обучающей). Для полноценной оценки статистическими критериями протокол валидации моделей построенных на наборе данных выглядел следующим образом:

- 1) четыре раза проводилась 5-кратная валидация на основе подразбиений обучающего набора, для получения 20 оценок эффективности модели;
- 2) четыре раза проводилось обучение на изначально предоставленном разбиении.

Таким образом, в ходе валидации получались 24 оценки точности на обучающей и тестовой выборках, которые позже сравнивались с помощью парного критерия Уилкоксона.

Таблица 4.2 – Соотношение числа классов в наборе данных

Класс	Количество образцов	
	Обучающая выборка	Тестовая выборка
SPSW	141	46
GPED	2427	760
PLED	1715	596
EYEM	522	124
ARTF	1471	523
BCKG	3068	1062
Всего:	9344	3111

Также в ходе препроцессинга данных набор каналов усекался до набора каналов на оборудовании НИИКФ, а именно: Fp1, Fp2, F3, F4, C3, C4, P3, P4, O1, O2, F7, F8, T3, T4, T5, T6, A1, A2. По аналогии с оборудованием НИИКФ к данным был применен следующий монтаж: O2-A2, O1-A1, P4-A2, P3-A1, C4-A2, C3-A1, F4-A2, F3-A1, Fp1-A1, Fp2-A2, T6-A2, T5-A1, T4-A2, T3-A1, F8-A2, F7-A1, A1-A2. Под биполярным монтажом (который используется в данном случае) понимается разность между электрическим потенциалом, регистрируемым на электроде, исходным сигналом, и опорным узлом (например, электродом, подключенным к левому уху). В вышеприведенном монтаже опорный электрод – второй в паре. Монтажи применяются для снижения уровня шума в сигнале. Данный процесс называется референсингом сигнала ЭЭГ (referencing) (Рисунок 4.6).

Данные были разделены на эпохи длительностью равной 1 секунде. После обработки имеем следующую размерность набора данных - [8715 образцов, 64 канала]. Каждый образец представляет собой временной ряд из 161 временных отсчетов, поэтому можно представить размерность в следующем виде - [8715 образцов, 64 канала, 161 временной отсчет]. Для упрощения процесса обучения, было произведено понижение частоты дискретизации сигнала до частоты 125 Гц. После этого набор данных имеет следующую размерность (до разбиения на обучающие и тестовые выборки) - [12455 образца, 17 каналов, 126 временных отсчетов]. Дополнительная

фильтрация или предобработка до применения метода Гильберта-Хуанга и Холо-Гильберта (которые используются для процессинга сигнала и построения спектрограмм для классификации наличия или отсутствия эпилептиформ) не проводилась. Пример спектрограммы приведен на Рисунке 4.7.




Рисунок 4.6 – Примеры референсинга сигнала

Был выбран интересующий диапазон частотной модуляции 0–65 Гц, для амплитудной модуляции (0–8 Гц). После этого набор данных для преобразования Гильберта-Хуанга имеет следующую размерность - [8715 образцов, 17 каналов, 65 FM диапазонов, 126 временных отсчетов]. Для преобразования Холо-Гильберта размерность также скорректирована - [8715 образцов, 17 каналов, 65 FM диапазонов, 2 AM диапазона, 126 временных отсчетов].

В качестве альтернативных методов извлечения были методы дискретного вейвлет-преобразования (в этом случае получено 306 признаков на сегмент) и методы Common Spatial Pattern (CSP) [199] матриц, спроецированных в пространство меньшей размерности (153 признака). Также рассматриваются модели на основе одиночных деревьев решений, ансамблей деревьев решений, классификатора на основе машины опорных векторов. Для решаемой задачи также используются нейронные сети на основе преобразований Гильберта-Хуанга и Холо-Гильберта, одномерных,

двумерных, трехмерных сверток (Таблица 4.3, Таблица 4.4, Таблица 4.5, Таблица 4.6).

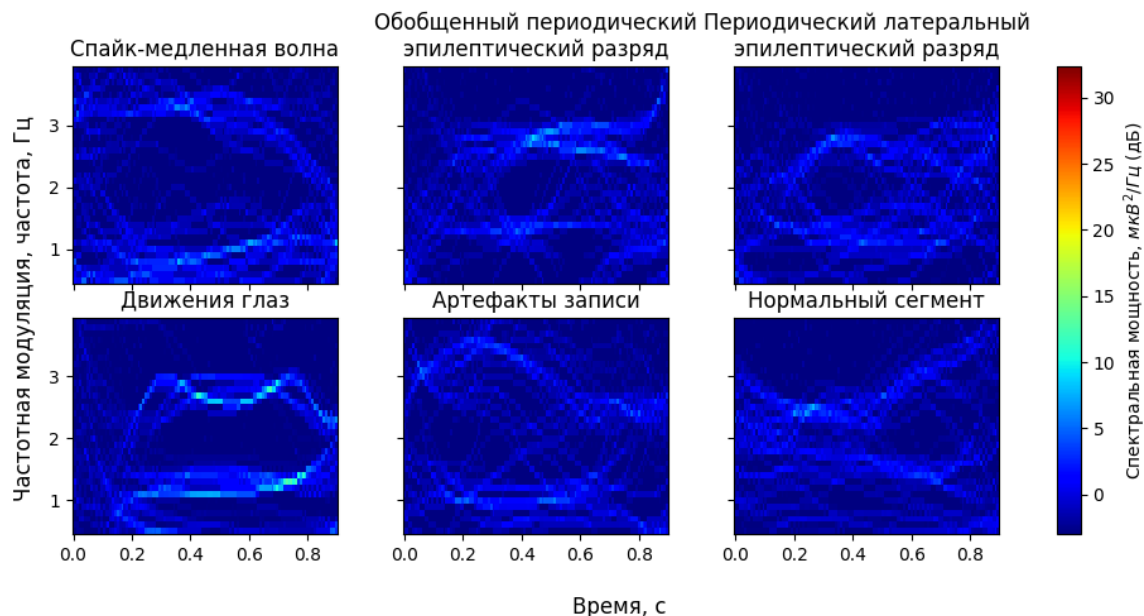


Рисунок 4.7 – Примеры спектрограмм частотной модуляции, полученных с помощью преобразования Гильберта-Хуанга для различных классов

В Таблице 4.7 приведены основные обозначения и характеристики для используемых архитектур и моделей. Для решения задач классификации эпилептиформ метрическое обучение не использовалась, использовалась функция потерь кросс-энтропии. В Таблице 4.7 также приведены результаты валидации моделей, в качестве метрики точности используется процент правильной классификации.

Проведено сравнение двух архитектур на основе преобразования Гильберта-Хуанга, одна из которых рассматривает спектрограмму как двумерное изображение, а другая – как совокупность временных рядов значений спектральной мощности, каждый из которых соответствует определенному частотному диапазону. Результаты приведены в Таблице 4.8 и показывают превосходство архитектуры на основе одномерных сверток. Аналогичное сравнение проведено для архитектур на основе преобразования Холо-Гильберта, в этом случае сравнивается спектральное трехмерное представление сигнала с его декомпозицией на временные ряды, где каждое

значение соответствует паре определенных частотных диапазонов частотной и амплитудной модуляции. Результаты проверки по критерию Уилкоксона также приведены в Таблице 4.9 и тоже показывают превосходство архитектур, на основе одномерных сверток.

Таблица 4.3 - Архитектура сети на основе преобразования Гильберта-Хуанга и одномерных сверток

Слой	Число фильтров / нейронов	Размер фильтров / ядер	Размерность входа	Число параметров	Функция активации выхода
Conv1D (padding=1)	512	2	[17*65, 126]	1132032	-
Maxpool1D	-	2	[512, 127]	-	-
BatchNorm1D	-	-	[512, 64]	1024	SiLU
Conv1D	256	2	[512, 64]	262400	-
Maxpool1D	-	2	[256, 63]	-	-
BatchNorm1D	-	-	[256, 31]	512	SiLU
Conv1D	128	2	[256, 31]	65664	-
Maxpool1D	-	2	[128, 30]	-	-
BatchNorm1D	-	-	[128, 15]	256	SiLU
Conv1D	64	3	[128, 13]	24640	-
Maxpool1D	-	3	[64, 4]	-	-
BatchNorm1D	-	-	[64, 4]	128	SiLU
Flatten	-	-	[64*4]	-	-
Linear	128	-	[128]	32896	-
Linear	2	-	[128]	258	-
Output	-	-	[2]	-	-

Таблица 4.4 - Архитектура сети на основе преобразования Гильберта-Хуанга и двумерных сверток

Слой	Число фильтров / нейронов	Размер фильтров / ядер	Размерность входа	Число параметров	Функция активации выхода
Conv2D (padding=1)	10	(2,2)	[17, 65, 126]	690	-
Maxpool2D	-	(2,2)	[10, 66, 127]	-	-
BatchNorm2D	-	-	[10, 34, 64]	20	SiLU
Conv2D	5	(2,2)	[10, 34, 64]	205	-
Maxpool2D	-	(2,2)	[5, 33, 63]	-	-
BatchNorm2D	-	-	[5, 16, 31]	10	SiLU
Conv2D	2	(2,2)	[5, 15, 30]	42	-
Maxpool2D	-	(2,2)	[2, 7, 15]	-	-
BatchNorm2D	-	-	[2, 7, 15]	4	SiLU
Flatten	-	-	[2*7*15]	-	-
Linear	128	-	[210]	27008	-
Linear	2	-	[128]	258	-
Output	-	-	[2]	-	-

Таблица 4.5 - Архитектура сети на основе преобразования Холо-Гильберта и одномерных сверток

Слой	Число фильтров / нейронов	Размер фильтров / ядер	Размерность входа	Число параметров	Функция активации выхода
Conv1D (padding=1)	512	2	[17*2*65, 126]	1044992	-
Maxpool1D	-	2	[512, 127]	-	-
BatchNorm1D	-	-	[512, 64]	1024	SiLU
Conv1D	256	2	[512, 64]	262400	-
Maxpool1D	-	2	[256, 63]	-	-
BatchNorm1D	-	-	[256, 31]	512	SiLU
Conv1D	128	2	[256, 31]	65664	-
Maxpool1D	-	2	[128, 30]	-	-
BatchNorm1D	-	-	[128, 15]	256	SiLU
Conv1D	64	3	[128, 13]	24640	-
Maxpool1D	-	3	[64, 4]	-	-
BatchNorm1D	-	-	[64, 4]	128	SiLU
Flatten	-	-	[64*4]	-	-
Linear	128	-	[128]	32896	-
Linear	2	-	[128]	258	-
Output	-	-	[2]	-	-

Таблица 4.6 - Архитектура сети на основе преобразования Холо-Гильберта и трехмерных сверток

Слой	Число фильтров / нейронов	Размер фильтров / ядер	Размерность входа	Число параметров	Функция активации выхода
Conv3D (padding=(1, 0, 1))	5	(3, 1, 3)	[18, 65, 2, 126]	815	-
Maxpool3D	-	(3, 1, 3)	[5, 22, 2, 115]	-	-
BatchNorm3D	-	-	[5, 22, 2, 39]	10	SiLU
Conv3D	2	(3, 1, 3)	[5, 22, 2, 39]	92	-
Maxpool3D	-	(3, 1, 3)	[2, 20, 2, 37]	-	-
BatchNorm3D	-	-	[2, 6, 2, 12]	4	SiLU
Flatten	-	-	[2*6*2*12]	-	-
Linear	128	-	[288]	36992	-
Linear	2	-	[128]	258	-
Output	-	-	[2]	-	-

Таблица 4.7 – Обозначения моделей и точность классификации эпилептиформ

Обозначение	Модель	Признаки или используемые преобразования	Число эпох обучения	Процент правильной классификации
DWT-SVC	LinearSVC	дискретное вейвлет-преобразование	-	68,19
CSP-Tree	Дерево решений	CSP-матрицы	-	69,88
2DCNN-Hilbert	нейронная сеть	преобразование Гильберта-Хуанга	20	74,48
3DCNN-Holo	нейронная сеть	преобразование Холо-Гильберта	20	74,64
DWT-Tree	Дерево решений	дискретное вейвлет-преобразование	-	75,38
CSP-Forest	Случайный лес	CSP-матрицы	-	78,58
CSP-SVC	LinearSVC	CSP-матрицы	-	79,75
DWT-Forest	Случайный лес	дискретное вейвлет-преобразование	-	81,62
1DCNN-Hilbert	нейронная сеть	преобразование Гильберта-Хуанга	20	84,63
1DCNN-Holo	нейронная сеть	преобразование Холо-Гильберта	20	85,29

Таблица 4.8 - Проверка наличия статистически значимых различий между архитектурами на основе преобразования Гильберта-Хуанга с помощью критерия Уилкоксона

Нулевая гипотеза	Между результатами сопоставляемых методов имеются лишь случайные различия
Сопоставляемые методы	1DCNN- Hilbert и 2DCNN-Hilbert
Значение критерия теста Уилкоксона	298.00
Асимптотическая значимость	<0,01
Результат	Нулевая гипотеза отклоняется

Таблица 4.9 - Проверка наличия статистически значимых различий между архитектурами на основе преобразования Холо-Гильберта с помощью критерия Уилкоксона

Нулевая гипотеза	Между результатами сопоставляемых методов имеются лишь случайные различия
Сопоставляемые методы	1DCNN- Holo и 3DCNN-Holo
Значение критерия теста Уилкоксона	297,5
Асимптотическая значимость	<0,01
Результат	Нулевая гипотеза отклоняется

Таблица 4.10 - Проверка наличия статистически значимых различий между архитектурами на основе преобразования Холо-Гильберта и Гильберта-Хуанга с помощью критерия Уилкоксона

Нулевая гипотеза	Между результатами сопоставляемых методов имеются лишь случайные различия
Сопоставляемые методы	1DCNN- Holo и 1DCNN-Hilbert
Значение критерия теста Уилкоксона	249,0
Асимптотическая значимость	<0,01
Результат	Нулевая гипотеза отклоняется

Таблица 4.11 - Проверка наличия статистически значимых различий между архитектурами на основе преобразования Холо-Гильберта и моделью-аналогом с помощью критерия Уилкоксона

Нулевая гипотеза	Между результатами сопоставляемых методов имеются лишь случайные различия
Сопоставляемые методы	1DCNN- Holo и DWT-Forest
Значение критерия теста Уилкоксона	281,5
Асимптотическая значимость	<0,01
Результат	Нулевая гипотеза отклоняется

В Таблице 4.10 приведены результаты проверки наличия статистически значимых различий между одномерными архитектурами на основе преобразования Гильберта-Хуанга и Холо-Гильберта. Результаты показывают наличие значимых различий, что свидетельствует о повышении точности обнаружения эпилептиформ при включении информации об амплитудной модуляции сигнала ЭЭГ.

Заключительная проверка проводилась на наличие разницы между одномерной архитектурой на основе преобразования Холо-Гильберта и ближайшей по точности моделью-аналогом, оперирующей признаками на основе дискретного вейвлет-преобразования (Таблица 4.11). Разница статистически значима, таким образом, наилучшим образом при решении задачи определения наличия эпилептиформ на основе данных ЭЭГ показывает себя архитектура на основе преобразования Холо-Гильберта и одномерных сверток, с итоговым значением процента правильной классификации равным 85,29%.

Полученная модель может автоматизировать процесс анализа данных ЭЭГ при использовании вместе с другим аппаратом снятия ЭЭГ в НИИКФ, который поддерживает открытый формат файла .edf. Недостатками нейросетевой модели являются повышенные требования к вычислительным ресурсам и времени (из-за применения вычислительно затратного метода Холо-Гильберта и большой длительности записей ЭЭГ, что ведет к увеличению числа обрабатываемых сегментов), а также недостаток интерпретируемости модели.

4.4 Выводы

Для решения задачи определения эпилептиформ на данных ЭЭГ в НИИКФ был собран набор данных для построения нечеткого классификатора. Данный классификатор превосходит модели-аналоги, достигая точности 84,40%. Итоговый нечеткий классификатор был построен на всех данных без разбиения на обучающую и тестовую выборки, в итоге отобрав следующие

признаки: суммарное относительное значение мощности для O2-A2, абсолютный коэффициент асимметрии ритма Бета2 для Fp1-Fp2, суммарное относительное значение мощности для O1-A1, относительное значение мощности для Альфа-ритма P4-A2, абсолютный коэффициент асимметрии ритма Бета2 для T3-T4, относительное значение мощности для ритма Бета2 и F4-A2, относительное значение мощности для ритма Бета2 и Fp2-A2, значение доминирующих частот для Альфа-ритма и P4-A2, значение доминирующих частот Альфа-ритма, P3-A1. На основе построенного нечеткого классификатора было построено веб-приложение в фреймворке Gradio.

Также предложена альтернативная модель на основе преобразования Холо-Гильберта, используя сторонний набор данных. Данная модель превосходит по точности аналоги, может автоматизировать процесс анализа данных ЭЭГ при использовании вместе с другим аппаратом снятия ЭЭГ в НИИКФ, который поддерживает открытый формат файла .edf. Недостатками нейросетевой модели являются повышенные требования к вычислительным ресурсам и времени (из-за применения вычислительно затратного метода Холо-Гильберта и большой длительности записей ЭЭГ, что ведет к увеличению числа обрабатываемых сегментов), а также недостаток интерпретируемости модели. По результатам работы получен акт внедрения (Приложение Г).

Заключение

В работе представлено решение задачи создания системы анализа электроэнцефалографических данных на основе нейро-сетевых и нечетких методов, имеющей значение для развития научных основ современных информационных технологий.

Для достижения цели были выполнены следующие задачи:

1) проведен обзор существующих методов верификации субъекта на основе данных электроэнцефалограммы, выявлены недостатки используемых протоколов валидации. Выявлены перспективные методы процессинга данных ЭЭГ, способы обучения и модели, среди которых предложены нечеткие классификаторы, как более интерпретируемые по сравнению с другими моделями;

2) разработан и исследован метод построения моделей верификации субъекта на основе данных электроэнцефалограммы с помощью нейронных сетей и метода спектрального анализа Холо-Гильберта;

3) разработан и исследован алгоритм формирования структуры нечеткого классификатора с помощью кластеризации и метаэвристических алгоритмов, а также оптимизации параметров классификатора;

4) разработан и исследован алгоритм отбора признаков с помощью метаэвристических алгоритмов для нечеткого классификатора;

5) выполнена проверка разработанных алгоритмов на наборах данных ЭЭГ и проведено сравнение с аналогами.

Для подтверждения эффективности предложенного гибридного алгоритма построения базы правил нечеткого классификатора, особенностью которого является использование кластеризации на основе метаэвристического алгоритма “стая птиц” был проведен эксперимент построения соответствующих нечетких классификаторов на 18 наборах данных репозитория Keel. Предложенный алгоритм превзошел по точности правильной классификации алгоритмы-аналоги АЭПК (прирост 14,38%

правильной классификации) и построения базы правил нечеткого классификатора с использованием кластеризации k -means (прирост 6,00% правильной классификации), разница статистически значима ($p < 0,01$).

Предложенный гибридный алгоритм построения базы правил нечеткого классификатора, особенностью которого является использование кластеризации на основе метаэвристического алгоритма “стая птиц”, и алгоритм отбора признаков, особенностью которого является использование V-образной функции трансформации и метаэвристического алгоритма “стая птиц”, применены для решения задачи верификации на основе данных ЭЭГ PhysioNet. Нечеткий классификатор, построенный на основе предлагаемых методов, превосходит классификатор на основе машины опорных векторов с линейным ядром (прирост 6,46% правильной классификации) и нечеткий классификатор на основе АЭПК (прирост 9,37% правильной классификации) по точности. Полученный нечеткий классификатор более интерпретируем, чем классификатор на основе машины опорных векторов, однако большое число признаков и правил все еще затрудняют возможности интерпретации.

По результатам эксперимента оригинальный метод верификации субъекта на основе данных, отличительной особенностью которого является использование извлечения признаков с помощью преобразования Холо-Гильберта и метрического обучения, показал статистически значимое снижение ошибки по сравнению с архитектурой на основе дискретного вейвлет-преобразования (снижение на 9,38% метрики ошибки EER) и преобразования Гильберта-Хуанга (снижение 0,97% метрики ошибки EER, с 10,92% до 9,95%). Также показано статистически значимое снижение ошибки при использовании архитектур на основе одномерных сверток на результатах преобразования Гильберта-Хуанга и Холо-Гильберта. Для двух протоколов валидации, LeavePGroupsOut и KFold, выявлены статистически значимые различия и подтверждено, что полное исключение субъектов тестовой выборки из обучающей значительно повышает значение метрики ошибки

системы. Протокол LeavePGroupsOut выбран для применения, как более полно отражающий условия работы системы верификации в реальном мире.

Полученные метод и алгоритмы могут применяться как для задач верификации на основе ЭЭГ, мультиклассовой классификации сегментов ЭЭГ, так и для других задач обработки сигнала и в сфере машинного обучения в научно-исследовательских и практических целях, что подтверждено при решении практической задачи определения эпилептиформной активности в данных ЭЭГ.

Литература

- 1) ГОСТ ISO/IEC 19794-1-2015 Информационные технологии. Биометрия. Форматы обмена биометрическими данными. Часть 1. Структура. М.: Стандартинформ, 2018. 25 с.
- 2) Jain A. K., Ross A., Prabhakar S. An Introduction to Biometric Recognition // IEEE Trans. Circuits Syst. Video Technol. 2004. – Vol. 14. – № 1. – P. 4–20.
- 3) Paderes R. E. O. A Comparative Review of Biometric Security Systems // 2015 8th International Conference on Bio-Science and Bio-Technology (BSBT). – 2015. – P. 8–11.
- 4) Review on EEG-Based Authentication Technology / Zhang S. [и др.] // Computational Intelligence and Neuroscience. – 2021. – Vol. 2021. – P. 1–20.
- 5) A review of classification algorithms for EEG-based brain–computer interfaces / Lotte F. [и др.] // J. Neural Eng. 2007. – Vol. 4. – № 2. – P. 1–13.
- 6) Maiorana E., La Rocca D., Campisi P. On the Permanence of EEG Signals for Biometric Recognition // IEEE Trans. Inform. Forensic Secur. – 2016. – Vol. 11. – № 1. – P. 163–175.
- 7) Ray-Dowling A. Examining Uniqueness and Permanence of the WAY EEG GAL dataset toward User Authentication [Электронный ресурс] // arXiv.org. 2022. URL: <https://arxiv.org/abs/2209.04802> (дата обращения: 22.01.2023).
- 8) Brainprint: Assessing the uniqueness, collectability, and permanence of a novel method for ERP biometrics / Armstrong B. C. [и др.] // Neurocomputing. 2015. – Vol. 166. – С. 59–67.
- 9) Ruiz Blondet M. V., Laszlo S., Jin Z. Assessment of permanence of non-volitional EEG brainwaves as a biometric // IEEE International Conference on Identity, Security and Behavior Analysis (ISBA 2015). – 2015. – P. 1–6.
- 10) Anti-deception: reliable EEG-based biometrics with real-time capability from the neural response of face rapid serial visual presentation / Wu Q. [и др.] // BioMed Eng OnLine. – 2018. – Vol. 17. – № 1. – P. 1–16.

- 11) Human Brain Distinctiveness Based on EEG Spectral Coherence Connectivity / Rocca D. L. [и др.] // IEEE Trans. Biomed. Eng. 2014. – Vol. 61. – № 9. – P. 2406–2412.
- 12) Sharma P., Justus J. C., Poudel G. R. Sensors and Systems for Monitoring Mental Fatigue: A systematic review [Электронный ресурс] // arXiv, 2023. URL: <https://arxiv.org/abs/2307.01666> (дата обращения: 12.09.2023).
- 13) ГОСТ Р 58833–2020 Защита информации. Идентификация и аутентификация. Общие положения. М.: Стандартинформ, 2020. 32 с.
- 14) Chato L., Latifi S. Application of Machine Learning to Biometric Systems- A Survey // J. Phys.: Conf. Ser. – 2018. – Vol. 1098. – P. 1–5.
- 15) Kokal S., Vanamala M., Dave R. Deep Learning and Machine Learning, Better Together Than Apart: A Review on Biometrics Mobile Authentication // JCP. 2023. – Vol. 3. – № 2. – P. 227–258.
- 16) Kaya M., Bilge H. Deep Metric Learning: A Survey // Symmetry. – 2019. – Vol. 11. – № 9. – P. 1-26.
- 17) Singh A. K., Krishnan S. Trends in EEG signal feature extraction applications // Front. Artif. Intell. – 2023. – Vol. 5. – P. 1–17.
- 18) On Holo-Hilbert spectral analysis: a full informational spectral representation for nonlinear and non-stationary data / Huang N. E. [и др.] // Phil. Trans. R. Soc. A. – 2016. – Vol. 374. – № 2065. – P. 1–21.
- 19) Doshi-Velez F., Kim B. Towards A Rigorous Science of Interpretable Machine Learning [Электронный ресурс] // arXiv, 2017. URL: <https://arxiv.org/abs/1702.08608> (дата обращения: 12.09.2023).
- 20) Saranya A., Subhashini R. A systematic review of Explainable Artificial Intelligence models and applications: Recent developments and future trends // Decision Analytics Journal. – 2023. – Vol. 7. – P. 1–16.
- 21) Zadeh L. A. Fuzzy sets // Information and Control. – 1965. – Vol. 8. – № 3. – P. 338–353.

- 22) Hybrid-ensemble-based interpretable TSK fuzzy classifier for imbalanced data / Bian Z. [и др.] // Information Fusion. – 2023. – Vol. 98. – P. 1–16.
- 23) Cross-Domain TSK Fuzzy System Based on Semi-Supervised Learning for Epilepsy Classification / Cheng Z. [и др.] // Computer Modeling in Engineering & Sciences. – 2023. – Vol. 137. – № 2. – P. 1613–1633.
- 24) A novel multi-task TSK fuzzy classifier and its enhanced version for labeling-risk-aware multi-task classification / Jiang Y. [и др.] // Information Sciences. – 2016. – Vol. 357. – P. 39–60.
- 25) Hybrid-ensemble-based interpretable TSK fuzzy classifier for imbalanced data / Bian Z. [и др.] // Information Fusion. – 2023. – Vol. 98.
- 26) Altman N., Krzywinski M. The curse(s) of dimensionality // Nat Methods. 2018. – Vol. 15. – № 6. – P. 399–400.
- 27) Al-Nafjan A. Feature selection of EEG signals in neuromarketing // PeerJ Computer Science. – 2022. – Vol. 8.
- 28) Shokooh T., Nadimi-Shahraki M. H. A Binary Metaheuristic Algorithm for Wrapper Feature Selection // International Journal of Computer Science Engineering. – 2019. – Vol. 8. – P. 168-172.
- 29) Hodashinsky I. A., Sarin K. S. Feature selection: Comparative Analysis of Binary Metaheuristics and Population Based Algorithm with Adaptive Memory // Program Comput Soft. – 2019. – Vol. 45. – № 5. – P. 221–227.
- 30) Metaheuristic Algorithms on Feature Selection: A Survey of One Decade of Research (2009-2019) / Agrawal P. [и др.] // IEEE Access. 2021. – Vol. 9. – P. 26766–26791.
- 31) Ince R., Adanır S. S., Sevmez F. The inventor of electroencephalography (EEG): Hans Berger (1873–1941) // Childs Nerv Syst. – 2020. – Vol. 37. – № 9. – P. 2723–2724.

32) Stone J. L., Hughes J. R. Early History of Electroencephalography and Establishment of the American Clinical Neurophysiology Society // *Journal of Clinical Neurophysiology*. – 2013. – Vol. 30. – № 1. – P. 28–44.

33) Jellinger K. A. Niedermeyer's Electroencephalography: Basic Principles, Clinical Applications, and Related Fields // *European Journal of Neurology*. – 2011. – Vol. 18. – № 9. – P. 1–16.

34) A History and Review of Quantitative Electroencephalography in Traumatic Brain Injury / Wallace B. E. [и др.] // *Journal of Head Trauma Rehabilitation*. – 2001. – Vol. 16. – № 2. – P. 165–190.

35) A Survey on EEG Signal Processing Techniques and Machine Learning: Applications to the Neurofeedback of Autobiographical Memory Deficits in Schizophrenia / Lujan M. [и др.] // *Electronics*. – 2021. – Vol. 10. – № 23. – P. 1-19.

36) Role of EEG as Biomarker in the Early Detection and Classification of Dementia / Al-Qazzaz N. K. [и др.] // *The Scientific World Journal*. – 2014. – Vol. 2014. – P. 1–16.

37) Millivolt-Scale DC Shifts in the Human Scalp EEG: Evidence for a Nonneuronal Generator / Voipio J. [и др.] // *Journal of Neurophysiology*. – 2003. – Vol. 89. – № 4. – P. 2208–2214.

38) Sampling rate, signal bandwidth and related pitfalls in EEG analysis / Weiergräber M. [и др.] // *Journal of Neuroscience Methods*. – 2016. – Vol. 268. – P. 53–55.

39) Maby E. Technical Requirements for High-quality EEG Acquisition // *Brain-Computer Interfaces*. – 2016. – P. 143–161.

40) Jurcak V., Tsuzuki D., Dan I. 10/20, 10/10, and 10/5 systems revisited: Their validity as relative head-surface-based positioning systems // *NeuroImage*. – 2007. – Vol. 34. – № 4. – P. 1600–1611.

- 41) Hosseini M.-P., Hosseini A., Ahi K. A Review on Machine Learning for EEG Signal Processing in Bioengineering // *IEEE Rev. Biomed. Eng.* – 2021. – Vol. 14. – P. 204–218.
- 42) Merlin Praveena D., Angelin Sarah D., Thomas George S. Deep Learning Techniques for EEG Signal Applications – A Review // *IETE Journal of Research.* – 2020. – Vol. 68. – № 4. – P. 3030–3037.
- 43) DeepSleepNet: A Model for Automatic Sleep Stage Scoring Based on Raw Single-Channel EEG / Supratak A. [и др.] // *IEEE Trans. Neural Syst. Rehabil. Eng.* – 2017. – Vol. 25. – № 11. – P. 1998–2008.
- 44) EEG-Based Brain-Computer Interfaces: A Thorough Literature Survey / Hwang H.-J. [и др.] // *International Journal of Human-Computer Interaction.* 2013. – Vol. 29. – № 12. – P. 814–826.
- 45) A novel pattern with high-level commands for encoding motor imagery-based brain computer interface / Zhang S. [и др.] // *Pattern Recognition Letters.* – 2019. – Vol. 125. – P. 28–34.
- 46) Decoding of motor imagery EEG based on brain source estimation / Li M.-A. [и др.] // *Neurocomputing.* – 2019. – Vol. 339. – P. 182–193.
- 47) Nourmohammadi A., Jafari M., Zander T. O. A Survey on Unmanned Aerial Vehicle Remote Control Using Brain–Computer Interface // *IEEE Trans. Human-Mach. Syst.* – 2018. – Vol. 48. – № 4. – P. 337–348.
- 48) Shared control of a robotic arm using non-invasive brain–computer interface and computer vision guidance / Xu Y. [и др.] // *Robotics and Autonomous Systems.* 2019. – Vol. 115. – P. 121–129.
- 49) Higashi H., Tanaka T. Simultaneous Design of FIR Filter Banks and Spatial Patterns for EEG Signal Classification // *IEEE Trans. Biomed. Eng.* – 2013. – Vol. 60. – № 4. – P. 1100–1110.
- 50) Kevric J., Subasi A. Comparison of signal decomposition methods in classification of EEG signals for motor-imagery BCI system // *Biomedical Signal Processing and Control.* – 2017. – Vol. 31. – P. 398–406.

- 51) SVM-based Brain–Machine Interface for controlling a robot arm through four mental tasks / Hortal E. [и др.] // *Neurocomputing*. – 2015. – Vol. 151. – P. 116–121.
- 52) Tabar Y. R., Halici U. A novel deep learning approach for classification of EEG motor imagery signals // *J. Neural Eng.* – 2016. – Vol. 14. – № 1. – P. 1–16.
- 53) Feature learning from incomplete EEG with denoising autoencoder / Li J. [и др.] // *Neurocomputing*. – 2015. – Vol. 165. – P. 23–31.
- 54) Higashi H., Tanaka T. Simultaneous Design of FIR Filter Banks and Spatial Patterns for EEG Signal Classification // *IEEE Trans. Biomed. Eng.* – 2013. – Vol. 60. – № 4. – P. 1100–1110.
- 55) A novel pattern with high-level commands for encoding motor imagery-based brain computer interface / Zhang S. [и др.] // *Pattern Recognition Letters*. – 2019. – Vol. 125. – P. 28–34.
- 56) Covariate shift estimation based adaptive ensemble learning for handling non-stationarity in motor imagery related EEG-based brain-computer interface / Raza H. [и др.] // *Neurocomputing*. – 2019. – Vol. 343. – P. 154–166.
- 57) Filter Bank Common Spatial Pattern Algorithm on BCI Competition IV Datasets 2a and 2b / Ang K. K. [и др.] // *Front. Neurosci.* – 2012. – Vol. 6. – P. 1–16.
- 58) Deep learning with convolutional neural networks for EEG decoding and visualization / Schirrmester R. T. [и др.] // *Hum. Brain Mapp.* – 2017. – Vol. 38. – № 11. – P. 5391–5420.
- 59) Deep learning based on Batch Normalization for P300 signal detection / Liu M. [и др.] // *Neurocomputing*. – 2018. – Vol. 275. – P. 288–297.
- 60) Toward enhanced P300 speller performance / Krusienski D. J. [и др.] // *Journal of Neuroscience Methods*. – 2008. – Vol. 167. – № 1. – P. 15–21.
- 61) Salvaris M., Sepulveda F. Visual modifications on the P300 speller BCI paradigm // *J. Neural Eng.* 2009. – Vol. 6. – № 4. – P. 1–16.

62) EEGNet: a compact convolutional neural network for EEG-based brain–computer interfaces // *J. Neural Eng.* – 2018. – Vol. 15. – № 5. – P. 1–16.

63) Improving classification accuracy of SVM ensemble using random training set for BCI P300-speller / Lawhern V. J. [и др.] // 2016 IEEE International Conference on Mechatronics and Automation. – 2016. – P. 2611-2616.

64) Akram F., Han S. M., Kim T.-S. An efficient word typing P300-BCI system using a modified T9 interface and random forest classifier // *Computers in Biology and Medicine.* – 2015. – Vol. 56. – P. 30–36.

65) Lee Y.-R., Kim H.-N. A data partitioning method for increasing ensemble diversity of an eSVM-based P300 speller // *Biomedical Signal Processing and Control.* – 2018. – Vol. 39. – P. 53–63.

66) A Survey of Stimulation Methods Used in SSVEP-Based BCIs / Zhu D. [и др.] // *Computational Intelligence and Neuroscience.* – 2010. – Vol. 2010. – P. 1–12.

67) A new hybrid BCI paradigm based on P300 and SSVEP / Wang M. [и др.] // *Journal of Neuroscience Methods.* – 2015. – Vol. 244. – P. 16–25.

68) Self-regulation of brain rhythms in the precuneus: a novel BCI paradigm for patients with ALS / Fomina T. [и др.] // *J. Neural Eng.* 2016. – Vol. 13. – № 6. – P. 1–16.

69) Lapses of responsiveness: Characteristics, detection, and underlying mechanisms / Jones R. D. [и др.] // 2010 Annual International Conference of the IEEE Engineering in Medicine and Biology. – 2010. – P. 1788–1791.

70) Frequent lapses of responsiveness during an extended visuomotor tracking task in non-sleep-deprived subjects / Peiris M. T. R. [и др.] // *J Sleep Res.* – 2006. – Vol. 15. – № 3. – P. 291–300.

71) Feature Fusion for the Detection of Microsleep Events / Golz M. [и др.] // *J VLSI Sign Process Syst Sign Im.* – 2007. – Vol. 49. – № 2. – P. 329–342.

72) Predicting Microsleep States Using EEG Inter-Channel Relationships / Buriro A. B. [и др.] // IEEE Trans. Neural Syst. Rehabil. Eng. – 2018. – Vol. 26. – № 12. – P. 2260–2269.

73) Shoorangiz R., Weddell S. J., Jones R. D. Prediction of microsleeps from EEG: Preliminary results // 2016 38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC). – 2016. – P. 4650–4653.

74) Golz M., Sommer D., Krajewski J. Prediction of immediately occurring microsleep events from brain electric signals // Current Directions in Biomedical Engineering. – 2016. – Vol. 2. – № 1. – P. 149–153.

75) Daskalaki E., Diem P., Mougiakakou S. G. An Actor–Critic based controller for glucose regulation in type 1 diabetes // Computer Methods and Programs in Biomedicine. – 2013. – Vol. 109. – № 2. – P. 116–125.

76) A simplified state-space model of biventricular assist device-cardiovascular system interaction / Koh V. C. A. [и др.] // 2016 38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC). – 2016. – P. 4370–4320.

77) Villanueva-Oller J., Villanueva R. J., Díez S. CASANDRA: A prototype implementation of a system of network progressive transmission of medical digital images // Computer Methods and Programs in Biomedicine. – 2007. – Vol. 85. – № 2. – P. 152–164.

78) Pang S., Orgun M. A., Yu Z. A novel biomedical image indexing and retrieval system via deep preference learning // Computer Methods and Programs in Biomedicine. – 2018. – Vol. 158. – P. 53–69.

79) A Speedy Hybrid BCI Spelling Approach Combining P300 and SSVEP / Erwei Yin [и др.] // IEEE Trans. Biomed. Eng. – 2014. – Vol. 61. – № 2. – P. 473–483.

80) The development of an automated machine learning pipeline for the detection of Alzheimer's Disease / Chedid N. [и др.] // *Sci Rep.* – 2022. – Vol. 12. – № 1. – P. 1–16.

81) A Survey on EEG Signal Processing Techniques and Machine Learning: Applications to the Neurofeedback of Autobiographical Memory Deficits in Schizophrenia / Luján M. [и др.]. // *Electronics.* – 2021. – Vol. 10. – № 23. – P. 1-16.

82) Bazgir O., Mohammadi Z., Habibi S. A. H. Emotion Recognition with Machine Learning Using EEG Signals // 2018 25th National and 3rd International Iranian Conference on Biomedical Engineering (ICBME). – 2018. – P. 1–5.

83) Sheoran M., Kumar S., Chawla S. Methods of denoising of electroencephalogram signal: a review // *IJBET.* – 2015. – Vol. 18. – № 4. – P. 385-395.

84) Dimigen O., Ehinger B. V. Regression-based analysis of combined EEG and eye-tracking data: Theory and applications // *Journal of Vision.* – 2021. – Vol. 21. – № 1. – P. 1–16.

85) Klados M. A. и др. REG-ICA: A hybrid methodology combining Blind Source Separation and regression techniques for the rejection of ocular artifacts // *Biomedical Signal Processing and Control.* – 2011. – Vol. 6. – № 3. – P. 291–300.

86) Improving Alzheimer's Disease Diagnosis with Machine Learning Techniques / Trambaiolli L. R. [и др.] // *Clin EEG Neurosci.* 2011. – Vol. 42. – № 3. – P. 160–165.

87) Kher R., Gandhi R. Adaptive filtering based artifact removal from electroencephalogram (EEG) signals // 2016 International Conference on Communication and Signal Processing (ICCSP). – 2016. – P. 1–16.

88) Sweeney K. T., Ward T. E., McLoone S. F. Artifact Removal in Physiological Signals—Practices and Possibilities // *IEEE Trans. Inform. Technol. Biomed.* 2012. – Vol. 16. № 3. – P. 488–500.

89) Shahbakhti M., Taherifar D., Zareei Z. Combination of PCA and SVM for diagnosis of Parkinson's disease // 2013 2nd International Conference on Advances in Biomedical Engineering. – 2013. – P. 1–16.

90) Neural Decoding of EEG Signals with Machine Learning: A Systematic Review / Saeidi M. [и др.] // Brain Sciences. – 2021. – Vol. 11. – № 11. – P. 1-44.

91) A Revised Hilbert-Huang Transformation to Track Non-Stationary Association of Electroencephalography Signals / Shan X. [и др.] // IEEE Trans. Neural Syst. Rehabil. Eng. – 2021. – Vol. 29. – P. 841–851.

92) Murugappan M. Human emotion classification using wavelet transform and KNN // 2011 International Conference on Pattern Analysis and Intelligence Robotics. – 2011. – P. 148-153.

93) Holo-Hilbert spectral-based noise removal method for EEG high-frequency bands / Moradi N. [и др.] // Journal of Neuroscience Methods. – 2022. – Vol. 368. – P. 1–16.

94) EEG Signal Analysis for Diagnosing Neurological Disorders Using Discrete Wavelet Transform and Intelligent Techniques / Alturki F. A. [и др.] // Sensors. – 2020. – Vol. 20. – № 9. – P. 1–16.

95) Classification of EEG Signals Based on Pattern Recognition Approach / Amin H. U. [и др.] // Front. Comput. Neurosci. – 2017. – Vol. 11. – P. 1-12.

96) Al-Fahoum A. S., Al-Fraihat A. A. Methods of EEG Signal Features Extraction Using Linear Analysis in Frequency and Time-Frequency Domains // ISRN Neuroscience. – 2014. – Vol. 2014. – P. 1–7.

97) Huang N. E., Wu Z. A review on Hilbert-Huang transform: Method and its applications to geophysical studies // Rev. Geophys. 2008. – Vol. 46. – № 2. – P. 1–23.

98) On Holo-Hilbert spectral analysis: a full informational spectral representation for nonlinear and non-stationary data / Huang N. E. [и др.] // Phil. Trans. R. Soc. A. 2016. – Vol. 374. – № 2065. – P. 20150206. – P. 1–21.

99) Taneski V., Hericko M., Brumen B. Password security & 2014; No change in 35 years? // 2014 37th International Convention on Information and Communication Technology, Electronics and Microelectronics (MIPRO). – 2014. – P. 1360–1365.

100) Unar J. A., Seng W. C., Abbasi A. A review of biometric technology along with trends and prospects // Pattern Recognition. – 2014. – Vol. 47. – № 8. – P. 2673–2688.

101) Kaur G., Singh G., Kumar V. A Review on Biometric Recognition // IJBSBT. – 2014. – Vol. 6. – № 4. – P. 69–76.

102) Whiskerd N., Dittmann J., Vielhauer C. A Requirement Analysis for Privacy Preserving Biometrics in View of Universal Human Rights and Data Protection Regulation // 2018 26th European Signal Processing Conference (EUSIPCO). – 2018. – P. 548–552.

103) Machine learning with ensemble stacking model for automated sleep staging using dual-channel EEG signal / Satapathy S. K. [и др.] // Biomedical Signal Processing and Control. – 2021. – Vol. 69. – P. 1–16.

104) Hussain I., Park S.-J. Quantitative Evaluation of Task-Induced Neurological Outcome after Stroke // Brain Sciences. – 2021. – Vol. 11. – № 7. – P. 1–21.

105) EEG-EMG Correlation for Parkinson's disease / Paul S. [и др.] // IJEAT. – 2019. – Vol. 8. – № 6. – P. 1179–1185.

106) A deep learning approach for Parkinson's disease diagnosis from EEG signals / Oh S. L. [и др.] // Neural Comput & Applic. – 2018. – Vol. 32. – № 15. – P. 10927–10933.

107) Piplani T., Merrill N., Chuang J. Faking it, Making it: Fooling and Improving Brain-Based Authentication with Generative Adversarial Networks // 2018 IEEE 9th International Conference on Biometrics Theory, Applications and Systems (BTAS). – 2018. – P. 1–7.

- 108) Review on Emotion Recognition Based on Electroencephalography / Liu H. [и др.] // *Front. Comput. Neurosci.* – 2021. – Vol. 15. – P. 1-15.
- 109) Suhaimi N. S., Mountstephens J., Teo J. EEG-Based Emotion Recognition: A State-of-the-Art Review of Current Trends and Opportunities // *Computational Intelligence and Neuroscience.* – 2020. – Vol. 2020. – P. 1–19.
- 110) EEG Emotion Recognition Using Dynamical Graph Convolutional Neural Networks / Song T. [и др.] // *IEEE Trans. Affective Comput.* – 2020. – Vol. 11. – № 3. – P. 532–541.
- 111) Emotion recognition from multichannel EEG signals using K-nearest neighbor classification / Li M. [и др.] // *THC.* – 2018. – Vol. 26. – P. 509–519.
- 112) Ross A., Jain A. K. Biometrics, Overview // *Encyclopedia of Biometrics.* – 2015. – P. 289–294.
- 113) Poulos M, Rangoussi M, Alexandris N, Evangelou A. On the use of EEG features towards person identification via neural networks. *Med Inform Internet Med.* – 2001 – Vol. 26 – P. 35-48.
- 114) Zhi Chin T., Saidatul A., Ibrahim Z. Exploring EEG based Authentication for Imaginary and Non-imaginary tasks using Power Spectral Density Method // *IOP Conf. Ser.: Mater. Sci. Eng.* – 2019. – Vol. 557. – № 1. – P. 012031.
- 115) An EEG-Based Person Authentication System with Open-Set Capability Combining Eye Blinking Signals / Wu Q. [и др.] // *Sensors.* – 2018. – Vol. 18. – № 2. – P. 1–16.
- 116) Robust Single-Trial EEG-Based Authentication Achieved with a 2-Stage Classifier / Barayeu U. [и др.] // *Biosensors.* – 2020. – Vol. 10. – № 9. – P. 1-13.
- 117) PhysioBank, PhysioToolkit, and PhysioNet / Goldberger A. L. [и др.] // *Circulation.* – 2000. – Vol. 101. – № 23.

118) Motor Movement/Imagery Dataset [Электронный ресурс]: Physionet.
URL: <https://physionet.org/content/eegmmidb/1.0.0/> (дата обращения:
16.01.2023).

119) EEG-based personal identification method using unsupervised feature extraction and its robustness against intra-subject variability / Nishimoto T. [и др.] // J. Neural Eng. – 2020. – Vol. 17. – № 2. – P. 1-15.

120) Monsy J. C., Vinod A. P. EEG-based biometric identification using frequency-weighted power feature // IET biom. – 2020. – Vol. 9. – № 6. – P. 251–258.

121) Moctezuma L. A., Molinas M. EEG-based subject identification with multi-class classification // Biosignal Processing and Classification Using Computational Learning and Intelligence. – 2022. – P. 293–306.

122) Kaliraman B., Singh P., Duhan M. Use of EEG as a Unique Human Biometric Trait for Authentication of an Individual // Lecture Notes in Electrical Engineering. – 2020. – P. 277–286.

123) Maiorana E. Deep learning for EEG-based biometric recognition // Neurocomputing. – 2020. – Vol. 410. – P. 374–386.

124) Multi-factor EEG-based user authentication / Pham T. [и др.] // 2014 International Joint Conference on Neural Networks (IJCNN). – 2014. – P. 4029–4034.

125) Person authentication based on eye-closed and visual stimulation using EEG signals / Yap H. Y. [и др.] // Brain Inf. – 2021. – Vol. 8. – № 1. – P. 1–16.

126) Maiorana E., La Rocca D., Campisi P. On the Permanence of EEG Signals for Biometric Recognition // IEEE Trans.Inform.Forensic Secur. – 2016. – Vol. 11. – № 1. – P. 163–175.

127) Review on EEG-Based Authentication Technology / Zhang S. [и др.] // Computational Intelligence and Neuroscience. – 2021. – Vol. 2021. – P. 1–20.

128) Human Brain Distinctiveness Based on EEG Spectral Coherence Connectivity / Rocca D. L. [и др.] // *IEEE Trans. Biomed. Eng.* – 2014. – Vol. 61. – № 9. – P. 2406–2412.

129) Maiorana E., Solé-Casals J., Campisi P. EEG signal preprocessing for biometric recognition // *Machine Vision and Applications.* – 2016. – Vol. 27. – № 8. – P. 1351–1360.

130) Maiorana E., Rocca D. L., Campisi P. Eigenbrains and Eigentensorbrains: Parsimonious bases for EEG biometrics // *Neurocomputing.* – 2016. – Vol. 171. – P. 638–648.

131) Suppiah R., Vinod A. P. Biometric identification using single channel EEG during relaxed resting state // *IET biom.* – 2018. – Vol. 7. – № 4. – P. 342–348.

132) Wang M., Hu J., Abbass H. A. BrainPrint: EEG biometric identification based on analyzing brain connectivity graphs // *Pattern Recognition.* – 2020. – Vol. 105. – P. 1–16.

133) Mao Z., Yao W. X., Huang Y. EEG-based biometric identification with deep learning // *2017 8th International IEEE/EMBS Conference on Neural Engineering (NER).* – 2017. – P. 609–612.

134) Sun Y., Lo F. P.-W., Lo B. EEG-based user identification system using 1D-convolutional long short-term memory neural networks // *Expert Systems with Applications.* 2019. – Vol. 125. – P. 259–267.

135) Convolutional Neural Networks Using Dynamic Functional Connectivity for EEG-Based Person Identification in Diverse Human States / Wang M. [и др.] // *IEEE Trans. Inform. Forensic Secur.* – 2019. – Vol. 14. – № 12. – P. 3259–3272.

136) Behrouzi T., Hatzinakos D. Graph variational auto-encoder for deriving EEG-based graph embedding // *Pattern Recognition.* – 2022. – Vol. 121. – P. 1–16.

137) Bidgoly A. J., Bidgoly H. J., Arezoumand Z. Towards a universal and privacy preserving EEG-based authentication system // *Sci Rep.* – 2022. – Vol. 12. – № 1. – P. 1–16.

138) Das R., Maiorana E., Campisi P. EEG Biometrics Using Visual Stimuli: A Longitudinal Study // *IEEE Signal Process. Lett.* – 2016. – Vol. 23. – № 3. – P. 341–345.

139) Jijomon C. M., Vinod A. P. EEG-based Biometric Identification using Frequently Occurring Maximum Power Spectral Features // *2018 IEEE Applied Signal Processing Conference (ASPCON)*. – 2018. – P. 249–252.

140) Convolutional Network for EEG-Based Biometric / Schons T. [и др.] // *Progress in Pattern Recognition, Image Analysis, Computer Vision, and Applications*. – 2018. – P. 601–608.

141) EEG-Based Person Identification and Authentication Using Deep Convolutional Neural Network / Alsumari W. [и др.] // *Axioms*. – 2023. – Vol. 12. – № 1. – P. 1-17.

142) On the Usage of Linear Regression Models to Reconstruct Limb Kinematics from Low Frequency EEG Signals / Antelis J. M. [и др.] // *PLoS ONE*. – 2013. – Vol. 8. – № 4. – P. 1-14.

143) Does deep learning always outperform simple linear regression in optical imaging? [Электронный ресурс] / Jiao S. [и др.] // *arXiv*, 2019. URL: <https://arxiv.org/abs/1911.00353> (дата обращения: 02.03.2023).

144) Cui C., Zhang Y., Zhong S. Explanations of Deep Networks on EEG Data via Interpretable Approaches // *2022 IEEE 35th International Symposium on Computer-Based Medical Systems (CBMS)*. – 2022. – P. 171-176.

145) Alsuradi H., Park W., Eid M. Explainable Classification of EEG Data for an Active Touch Task Using Shapley Values // *Lecture Notes in Computer Science*. – 2020. – P. 406–416.

146) Sundararajan M., Taly A., Yan Q. Axiomatic Attribution for Deep Networks [Электронный ресурс] // *arXiv*, 2017. URL: <https://arxiv.org/abs/1703.01365> (дата обращения: 02.03.2023).

147) Бардамова М. Б. Алгоритмы построения нечетких классификаторов несбалансированных данных на основе метаэвристик

"гравитационный поиск" и "прыгающие лягушки": дис. канд. техн. наук. Томск, 2021. 126 с.

148) Gu X., Angelov P. P., Principe J. C. A method for autonomous data partitioning // *Information Sciences*. – 2018. – Vol. 460. – P. 65–82.

149) A new bio-inspired optimisation algorithm: Bird Swarm Algorithm / Meng X.-B. [и др.] // *Journal of Experimental & Theoretical Artificial Intelligence*. – 2015. – Vol. 28. – № 4. – P. 673–687.

150) The Design of PID Controller Based on Improved Bird Swarm Algorithm / Qiao D. [и др.] // *2018 5th International Conference on Information, Cybernetics, and Computational Social Systems (ICCSS)*. – 2018. – P. 429–434.

151) A binary Bird Swarm Optimization technique for cloud computing task scheduling and load balancing / Kumar M. B. [и др.] // *2022 International Conference on Innovative Computing, Intelligent Communication and Smart Electrical Systems (ICSSES)*. – 2022. – Vol. 11 – P. 146–160.

152) Improved Swarm Intelligent Blind Source Separation Based on Signal Cross-Correlation / Zi J. [и др.] // *Sensors*. – 2021. – Vol. 22. – № 1. – P. 1-16.

153) EEG Feature Selection via Stacked Deep Embedded Regression With Joint Sparsity / Jiang K. [и др.] // *Front. Neurosci.* – 2020. – Vol. 14. – P. 1–9.

154) Jenke R., Peer A., Buss M. Feature Extraction and Selection for Emotion Recognition from EEG // *IEEE Trans. Affective Comput.* – 2014. – Vol. 5. – № 3. – P. 327–339.

155) Moon J. Extraction of User Preference for Video Stimuli Using EEG-Based User Responses // *ETRI J.* – 2013. – Vol. 35. – № 6. – P. 1105–1114.

156) Moctezuma L. A., Molinas M. EEG Channel-Selection Method for Epileptic-Seizure Classification Based on Multi-Objective Optimization // *Front. Neurosci.* – 2020. – Vol. 14. – P. 1-17.

157) EEG Channel Selection Based User Identification via Improved Flower Pollination Algorithm / Alyasseri Z. A. A. [и др.] // *Sensors*. – 2022. – Vol. 22. – № 6. – P. 1-16.

158) Seizure Classification From EEG Signals Using an Online Selective Transfer TSK Fuzzy Classifier With Joint Distribution Adaption and Manifold Regularization / Zhang Y. [и др.] // *Front. Neurosci.* – 2020. – Vol. 14. – P. 1-16.

159) Aydemir O., Kayikcioglu T. Decision tree structure based classification of EEG signals recorded during two dimensional cursor movement imagery // *Journal of Neuroscience Methods.* – 2014. – Vol. 229. – P. 68–75.

160) Multi-Similarity Loss with General Pair Weighting for Deep Metric Learning [Электронный ресурс] / Wang X. [и др.] // arXiv, 2019. URL: <https://arxiv.org/abs/1904.06627> (дата обращения: 02.03.2023).

161) Schroff F., Kalenichenko D., Philbin J. FaceNet: A Unified Embedding for Face Recognition and Clustering [Электронный ресурс] // arXiv, 2015. URL: <https://arxiv.org/abs/1503.03832> (дата обращения: 02.03.2023).

162) Svetlakov, M. Gender, Age and Number of Participants Effects on Identification Ability of EEG-based Shallow Classifiers / M. Svetlakov, I. Hodashinsky, A. Slezkin // *Proceedings - 2021 Ural Symposium on Biomedical Engineering, Radioelectronics and Information Technology, USBEREIT 2021, Yekaterinburg, 13–14 мая 2021 года.* – Yekaterinburg, 2021. – 2021. – P. 350-353.

163) Tsybenov, B. Feature Selection Methods Comparison for EEG-based Classifier Constructed Using Discrete Wavelet Transform Features / B. Tsybenov, M. Svetlakov, I. Hodashinsky // *Journal of Physics: Conference Series.* – 2022. – Vol. 2291. – № 1. – P. 1-6.

164) Цыбенков, Б. Д. Отбор и выделение признаков сигнала ЭЭГ с помощью вейвлет-преобразования для аутентификации пользователя / Б. Д. Цыбенков, М. О. Светлаков // *Электронные средства и системы управления. Материалы докладов Международной научно-практической конференции.* – 2021. – № 1. – С. 317–319.

165) Ходашинский И. А. Нечёткие классификаторы для диагностики болезни Паркинсона на основе статических рукописных данных / И. А. Ходашинский, Ю. А. Шурыгин, К. С. Сарин, М. Б. Бардамова, А. О. Слэзкин,

М. О. Светлаков, Н. П. Корышев // Автометрия. – 2023 – Т. 59, – №.3. – С. 72–85.

166) Hodashinsky, I. Identity Authentication Based on Handwritten Signature Using Fuzzy Classifiers Ensemble / I. Hodashinsky, A. Slezkin, M. Svetlakov, E. Kostyuchenko, I. Sidorov // International Journal of Advanced Research in Engineering and Technology. – 2021. – Vol.12. – P. 539-568.

167) Bardamova, M. Construction of Fuzzy Classifiers by a Brain Storm Optimization Algorithm / M. Bardamova, I. Hodashinsky, M. Svetlakov // Lecture Notes in Computer Science. – 2022. – P. 391–403.

168) Sarin K. A three-stage fuzzy classifier method for Parkinson's disease diagnosis using dynamic handwriting analysis // Decision Analytics Journal. – 2023. – Vol. 8. – P. 1-24.

169) Светлаков, М. О. Алгоритм оптимизации параметров нечеткого классификатора, использующий метаэвристику "стая птиц" и метод "островов" / М. О. Светлаков // Передовые инновационные разработки. Перспективы и опыт использования, проблемы внедрения в производство: Сборник научных статей по итогам шестой международной научной конференции, Казань, 31 июля 2019 года. – Казань: ООО "КОНВЕРТ", 2019. – 2019. – С. 224–226.

170) Svetlakov, M. O. Clustering-based rule generation methods for fuzzy classifier using Autonomous Data Partitioning algorithm / M. O. Svetlakov, I. A. Hodashinsky // Journal of Physics: Conference Series: 18, Tomsk, 27–30 April 2021. – 2021. – P. 1-6.

171) Светлаков, М. О. Применение алгоритма кластеризации Autonomous Data Partitioning для построения начальной базы правил нечетких классификаторов / М. О. Светлаков // Сборник избранных статей научной сессии ТУСУР. – 2020. – № 1. – С. 79–82.

172) Светлаков, М. О. Генерация правил нечеткого классификатора с помощью алгоритмов ADP и k -means / М. О. Светлаков // Перспективы

развития фундаментальных наук: Сборник научных трудов XVIII Международной конференции студентов, аспирантов и молодых ученых, Томск, 27–30 апреля 2021 года. Том 7. – Томск: Национальный исследовательский Томский политехнический университет, 2021. – 2021. – С. 107–109.

173) Генерация базы правил нечеткого классификатора для диагностики болезни Паркинсона по рукописным данным / М. Б. Бардамова, И. А. Ходашинский, Ю. А. Шурыгин [и др.] // Искусственный интеллект и принятие решений. – 2023. – № 2. – С. 31–44. – DOI 10.14357/20718594230203.

174) Hancer, E. Binary PSO Variants for Feature Selection in Handwritten Signature Authentication / E. Hancer, M. Bardamova, I. Hodashinsky, M. Svetlakov [и др.] // Informatica. – 2022. – Vol. 33. – No 3. – P. 523-543.

175) Светлаков, М. О. Отбор признаков для нечеткого классификатора с использованием метаэвристического алгоритма "bird swarm" / М. О. Светлаков // Сборник избранных статей научной сессии ТУСУР. – 2021. – № 1–2. – С. 230–233.

176) Светлаков, М. О. Применение нечеткого классификатора для аутентификации пользователя на основе данных электроэнцефалограммы / М. О. Светлаков // Электронные средства и системы управления. Материалы докладов Международной научно-практической конференции. – 2022. – № 1. – С. 214–217.

177) Svetlakov, M. Representation Learning for Electroencephalogram-Based Biometrics Using Holo-Hilbert Spectral Analysis / M. Svetlakov, I. Hodashinsky, K. Sarin // Pattern Recognition and Image Analysis. Advances in Mathematical Theory and Applications. – 2022. – Vol. 32. – No 3. – P. 682-688.

178) Svetlakov, M. Representation Learning for EEG-Based Biometrics Using Hilbert–Huang Transform / M. Svetlakov, I. Kovalev, A. Konev [и др.] // Computers. – 2022. – Vol. 11. – No 3. – P. 1–16.

179) Светлаков, М. О. Влияние выбора функции потерь на точность при обучении представлений с использованием данных электроэнцефалограммы для решения задачи идентификации субъекта / М. О. Светлаков // Сборник избранных статей научной сессии ТУСУР. – 2022. – № 1. – С. 92–94.

180)

181) EMD: Empirical Mode Decomposition and Hilbert-Huang Spectral Analyses in Python / Quinn A. [и др.] // JOSS. – 2021. – Vol. 6. – № 59. С. 1-8.

182) KEEL: a software tool to assess evolutionary algorithms for data mining problems / Alcalá-Fdez J. [и др.] // Soft Comput. – 2008. – Vol. 13. – № 3. – P. 307–318.

183) Scikit-learn: Machine Learning in Python [Электронный ресурс] / Pedregosa F. [и др.] // arXiv, 2012. URL: <https://arxiv.org/abs/1201.0490> (дата обращения: 02.03.2023).

184) PyTorch: An Imperative Style, High-Performance Deep Learning Library [Электронный ресурс] / Paszke A. [и др.] // arXiv, 2019. URL: <https://arxiv.org/abs/1912.01703> (дата обращения: 02.03.2023).

185) Musgrave K., Belongie S., Lim S.-N. PyTorch Metric Learning [Электронный ресурс] // arXiv, 2020. URL: <https://arxiv.org/abs/2008.09164> (дата обращения: 02.03.2023).

186) Sarin, K. Extracting Knowledge from Images of Meanders and Spirals in the Diagnosis of Patients with Parkinson's Disease / K. Sarin, I. Hodashinsky, M. Svetlakov // Pattern Recognition and Image Analysis. Advances in Mathematical Theory and Applications. – 2022. – Vol. 32. – No 3. – P. 658-664.

187) Ходашинский И. А. Нечёткие классификаторы для диагностики болезни Паркинсона на основе статических рукописных данных / И. А. Ходашинский, Ю. А. Шурыгин, К. С. Сарин, М. Б. Бардамова, А. О. Слёзкин,

М. О. Светлаков, Н. П. Корышев // Автометрия. – 2023 – Т. 59, – №.3. – С. 72–85.

188) Yamada T., Meng E. Practical guide for clinical neurophysiologic testing. Philadelphia: Wolters Kluwer, 2018. 360 с.

189) WHO updates fact sheet on Epilepsy [Электронный ресурс]: Community Medicine for Academics and Lay Learners. URL: <https://communitymedicine4all.com/2022/02/15/who-updates-fact-sheet-on-epilepsy-9-february-2022/> (дата обращения: 16.01.2023).

190) Tzallas A. T., Tsipouras M. G., Fotiadis D. I. Epileptic Seizure Detection in EEGs Using Time-Frequency Analysis // IEEE Trans. Inform. Technol. Biomed. – 2009. – Vol. 13. – № 5. – P. 703–710.

191) Waterhouse E. New horizons in ambulatory electroencephalography // IEEE Eng. Med. Biol. Mag. – 2003. – Vol. 22. – № 3. – P. 74–80.

192) Wearable Electroencephalography / Casson A. [и др.] // IEEE Eng. Med. Biol. Mag. – 2010. – Vol. 29. – № 3. – P. 44–56.

193) Westmoreland B. F. Epileptiform Electroencephalographic Patterns // Mayo Clinic Proceedings. – 1996. – Vol. 71. – № 5. – P. 501–511.

194) Chen T., Guestrin C. XGBoost // Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. – 2016. – P. 785-794.

195) Dorogush A. V., Ershov V., Gulin A. CatBoost: gradient boosting with categorical features support [Электронный ресурс] // arXiv, 2018. URL: <https://arxiv.org/abs/1810.11363> (дата обращения: 02.03.2023).

196) Gradio: Hassle-Free Sharing and Testing of ML Models in the Wild [Электронный ресурс] / Abubakar A. [и др.] // arXiv, 2019. URL: <https://arxiv.org/abs/1906.02569> (дата обращения: 02.03.2023).

197) Recent Advances in the TUH EEG Corpus: Improving the Interrater Agreement for Artifacts and Epileptiform Events / Buckwalter G. [и др.] // 2021

IEEE Signal Processing in Medicine and Biology Symposium (SPMB). – 2021. – P. 1-6.

198) Improved EEG event classification using differential energy / Harati A. [и др.] // 2015 IEEE Signal Processing in Medicine and Biology Symposium (SPMB). – 2015. – P. 1-6.

199) Machine learning for multivariate data analysis through the Riemannian geometry of symmetric or Hermitian positive definite matrices in Python [Электронный ресурс] / Varachant A. [и др.] // Github, 2023. URL: <https://github.com/pyRiemann/pyRiemann> (дата обращения: 02.03.2023).

Приложение А

Точность архитектур на основе метрического обучения и нейронных сетей

В Таблице А.1 и Таблице А.2 приведены значения метрик точности (процента правильной классификации и метрики EER) для различных архитектур нейронных сетей на основе преобразования Гильберта-Хуанга и Холо-Гильберта, а также альтернативного протокола валидации и модели-аналога.

Таблица А.1 – Процент правильной классификации для архитектур на основе метрического обучения и нейронных сетей

Номер итерации валидации	1DCNN-Hilbert-KF	1DCNN-Hilbert	2DCNN-Holo	1DCNN-Holo	3DCNN-Holo	DWT
1	96,98	89,09	87,37	89,65	87,93	79,54
2	96,96	88,50	88,75	88,42	86,19	78,41
3	98,06	88,85	84,47	91,43	85,52	80,67
4	98,02	87,54	84,85	88,97	86,10	81,50
5	98,44	89,14	85,47	90,28	86,76	79,76
6	96,26	88,43	86,09	89,48	87,22	80,41
7	97,91	88,28	84,29	91,37	88,74	80,43
8	97,92	90,01	84,00	89,58	87,48	81,17
9	98,26	88,54	84,57	88,93	86,66	80,71
10	97,76	89,89	84,94	88,83	88,10	76,14
11	96,56	90,69	85,53	89,97	86,76	82,27
12	97,24	88,11	87,37	89,77	87,56	77,69
13	97,68	91,15	85,13	89,54	85,69	81,29
14	97,34	90,29	87,41	89,84	86,00	79,88
15	97,82	87,54	85,72	89,56	89,47	80,55
16	96,77	88,78	83,44	89,77	87,62	81,19
17	97,82	89,22	84,45	91,11	87,03	79,99
18	98,11	88,85	85,69	89,84	85,99	78,64
19	97,87	90,13	84,45	91,07	86,94	80,95
20	98,05	87,36	83,44	89,30	86,28	80,55
среднее	97,59	89,02	85,37	89,84	87,00	80,09

Таблица А.2 – Значение метрики EER для архитектур на основе метрического обучения и нейронных сетей

Номер итерации валидации	1DCNN-Hilbert-KF	1DCNN-Hilbert	2DCNN-Holo	1DCNN-Holo	3DCNN-Holo	DWT
1	3,00	10,90	12,56	9,90	12,10	19,56
2	3,04	11,38	11,22	11,16	13,74	20,26
3	1,86	11,06	15,42	8,36	14,54	18,92
4	1,98	12,44	15,32	10,64	13,86	19,06
5	1,58	10,82	14,54	9,48	13,14	19,90
6	3,78	11,32	13,76	10,36	12,60	18,62
7	2,06	11,60	15,52	8,66	11,32	19,16
8	2,14	9,86	16,08	10,10	12,52	18,92
9	1,78	11,48	15,30	11,16	13,26	18,72
10	2,20	10,28	15,20	10,98	11,94	21,90
11	3,52	9,28	14,62	9,84	13,30	18,10
12	2,82	12,00	12,50	10,18	12,50	21,12
13	2,50	8,80	14,74	10,00	14,30	18,32
14	2,58	9,56	12,68	9,88	13,72	19,42
15	2,22	12,42	14,10	10,28	10,44	18,40
16	3,36	11,14	16,54	9,68	12,50	18,16
17	2,08	10,78	15,64	8,90	12,96	19,00
18	1,88	11,08	14,40	9,88	13,92	20,44
19	2,14	9,88	15,60	9,00	13,06	18,72
20	1,92	12,36	16,56	10,46	13,80	19,86
среднее	2,42	10,92	14,62	9,95	12,98	19,33

Приложение Б

Примеры из собранного набора данных для обнаружения эпилептиформ и результаты оценки построенных моделей

Таблица Б.1 – Пример собранных признаков для набора данных обнаружения эпилептиформ, абсолютные относительные значения мощностей

Абсолютные значения мощностей мкВ ²							
Имя	Дельта1	Дельта2	Тета	Альфа	Бета1	Бета2	Сумма
O2-A2	99,77	2276,88	631,78	242,58	48,23	28,27	3327,50
O1-A1	20,55	292,60	361,29	144,27	26,26	20,31	865,27
P4-A2	140,87	2152,50	465,19	167,73	47,27	24,97	2998,53
P3-A1	22,07	198,05	297,52	70,03	27,68	31,65	647,01
C4-A2	140,07	2116,33	324,22	126,17	46,22	24,99	2778,00
C3-A1	19,55	171,30	186,33	64,47	24,43	34,23	500,30
F4-A2	150,15	2176,30	267,48	96,58	44,66	25,33	2760,50
F3-A1	29,38	156,65	181,52	65,06	33,93	85,27	551,81
Fp2-A2	193,25	2184,63	254,73	88,54	44,04	23,16	2788,35
Fp1-A1	24,49	208,04	170,03	44,02	23,76	27,77	498,12
T6-A2	132,95	2046,09	323,36	161,24	64,33	34,09	2762,06
T5-A1	15,82	183,98	267,02	74,44	54,50	74,94	670,70
T4-A2	164,69	2173,66	291,21	133,05	59,46	37,12	2859,19
T3-A1	9,44	165,45	218,30	72,32	47,73	83,28	596,53
F8-A2	164,78	2151,43	260,62	102,61	53,56	31,90	2764,89
F7-A1	16,47	165,07	210,38	70,10	52,78	115,21	630,01
A1-A2	97,29	1657,08	405,21	33,96	24,06	20,70	2238,30
A1-N	15369,80	563,54	768,57	4255,47	14488,46	7011708	7047154,00
ЭЭГ	0,00	0,00	0,00	0,00	0,00	0,00	0,00
Сумма	16811,39	21039,59	5884,75	6012,64	15211,36	7012431	7012431,00
Относительные значения мощностей %							
Имя	Дельта1	Дельта2	Тета	Альфа	Бета1	Бета2	Сумма
O2-A2	2,96	67,58	18,75	7,20	1,43	0,84	98,76
O1-A1	2,26	32,20	39,75	15,87	2,89	2,23	95,21
P4-A2	4,64	70,90	15,32	5,52	1,56	0,82	98,77
P3-A1	3,13	28,05	42,14	9,92	3,92	4,48	91,65
C4-A2	4,98	75,21	11,52	4,48	1,64	0,89	98,72
C3-A1	3,48	30,52	33,20	11,49	4,35	6,10	89,15
F4-A2	5,37	77,89	9,57	3,46	1,60	0,91	98,80
F3-A1	4,82	25,73	29,81	10,69	5,57	14,01	90,63
Fp2-A2	6,84	77,36	9,02	3,14	1,56	0,82	98,74
Fp1-A1	4,51	38,31	31,31	8,11	4,38	5,11	91,73
T6-A2	4,72	72,59	11,47	5,72	2,28	1,21	97,99
T5-A1	1,92	22,28	32,34	9,02	6,60	9,08	81,23
T4-A2	5,65	74,52	9,98	4,56	2,04	1,27	98,02
T3-A1	1,30	22,74	30,00	9,94	6,56	11,45	81,98
F8-A2	5,86	76,52	9,27	3,65	1,90	1,13	98,34
F7-A1	2,12	21,22	27,05	9,01	6,79	14,81	81,00
A1-A2	4,29	73,11	17,88	1,50	1,06	0,91	98,75
A1-N	0,16	0,01	0,01	0,04	0,15	71,55	71,91
ЭЭГ	0,00	0,00	0,00	0,00	0,00	0,00	0,00
Среднее	3,63	46,67	19,92	6,49	2,96	7,77	7,77

Таблица Б.2 – Пример собранных признаков для набора данных обнаружения эпилептиформ, значения доминирующих и средневзвешенных частот

Значения доминирующих частот Гц						
Имя	Дельта1	Дельта2	Тета	Альфа	Бета1	Бета2
O2-A2	1,71	3,66	3,91	8,54	12,94	30,76
O1-A1	1,71	2,69	4,64	8,54	14,65	24,90
P4-A2	1,71	2,93	3,91	7,81	12,94	29,79
P3-A1	1,71	3,66	4,64	8,30	12,94	24,90
C4-A2	1,71	2,20	3,91	7,81	12,94	29,79
C3-A1	1,71	2,20	4,15	7,81	12,94	24,90
F4-A2	1,71	2,20	3,91	8,30	12,94	34,18
F3-A1	1,71	2,20	4,64	8,06	12,94	24,90
Fp2-A2	1,71	2,20	3,91	8,30	12,94	32,71
Fp1-A1	1,71	2,20	4,64	8,06	12,94	25,15
T6-A2	1,71	2,20	3,91	7,81	12,94	29,79
T5-A1	1,71	3,66	4,15	8,30	12,94	24,90
T4-A2	1,71	2,20	3,91	7,81	12,94	34,67
T3-A1	1,71	2,44	4,15	8,30	12,94	24,90
F8-A2	1,71	2,20	3,91	7,81	12,94	29,79
F7-A1	1,71	2,44	4,15	7,81	12,94	33,94
A1-A2	1,71	3,17	3,91	9,77	16,85	32,71
A1-N	0,49	1,95	7,57	12,45	23,44	24,90
ЭЭГ	0,73	2,20	4,15	8,06	15,87	31,01
Среднее	1,59	2,56	4,32	8,40	13,94	28,87
Значения средневзвешенных частот Гц						
Имя	Дельта1	Дельта2	Тета	Альфа	Бета1	Бета2
O2-A2	1,72	2,95	4,75	8,89	17,22	29,54
O1-A1	1,72	3,02	5,30	9,19	17,94	28,99
P4-A2	1,74	2,92	4,81	8,90	17,22	29,63
P3-A1	1,70	2,89	5,10	9,32	17,93	28,79
C4-A2	1,73	2,89	4,89	9,01	17,13	29,71
C3-A1	1,68	2,82	5,24	9,47	18,08	29,09
F4-A2	1,73	2,88	4,89	9,30	16,62	29,68
F3-A1	1,73	2,76	5,45	9,69	17,43	26,79
Fp2-A2	1,75	2,85	4,80	9,35	16,75	30,05
Fp1-A1	1,75	2,62	5,19	9,41	17,35	29,32
T6-A2	1,73	2,85	4,94	9,02	16,94	29,80
T5-A1	1,65	2,93	5,12	9,98	18,36	28,69
T4-A2	1,74	2,86	4,99	9,11	17,09	29,97
T3-A1	1,61	2,86	5,13	10,07	18,45	29,16
F8-A2	1,73	2,86	5,02	9,30	16,81	29,92
F7-A1	1,65	2,80	5,28	10,17	18,02	29,62
A1-A2	1,70	3,04	4,52	9,81	17,76	29,88
A1-N	0,71	2,64	6,15	10,98	18,63	25,13
ЭЭГ	1,14	2,92	5,56	9,93	17,17	29,05
Среднее	1,63	2,86	5,11	9,52	17,52	29,10

Таблица Б.3 – Пример собранных признаков для набора данных обнаружения эпилептиформ, коэффициенты асимметрии

Относительный коэффициент асимметрии %							
Имя	Дельта1	Дельта2	Тета	Альфа	Бета1	Бета2	Среднее
Fp1 - Fp2	200,86	168,05	28,76	41,34	46,43	-10,50	79,16
F7 - F8	176,52	168,88	17,06	30,18	1,79	-189,76	34,11
F3 - F4	143,74	171,71	29,19	29,26	24,57	-136,53	43,66
T3 - T4	184,77	170,74	24,76	56,39	26,85	-105,13	59,73
C3 - C4	143,44	165,37	46,83	57,29	49,89	-21,03	73,63
T5 - T6	139,41	158,32	19,14	80,60	22,51	-93,04	54,49
P3 - P4	141,39	166,17	56,95	90,71	44,86	-15,21	80,81
O1 - O2	94,28	168,70	91,87	91,28	50,31	18,13	85,76
Среднее	153,05	167,24	39,32	59,63	33,40	-69,13	-69,13
Коэффициент частотной асимметрии %							
Имя	Дельта1	Дельта2	Тета	Альфа	Бета1	Бета2	
Fp1 - Fp2	4,04	22,89	43,54	17,76	39,13	44,33	
F7 - F8	10,82	19,76	51,41	27,54	34,36	32,69	
F3 - F4	5,51	23,58	55,52	22,35	31,44	78,82	
T3 - T4	21,21	16,45	51,22	35,94	33,01	32,89	
C3 - C4	4,69	15,68	59,42	19,18	28,62	35,86	
T5 - T6	14,44	15,93	53,95	38,57	33,71	36,96	
P3 - P4	9,33	14,33	59,67	21,30	29,92	38,06	
O1 - O2	9,33	19,41	60,85	20,91	39,89	38,53	
Абсолютный коэффициент асимметрии %							
Имя	Дельта1	Дельта2	Тета	Альфа	Бета1	Бета2	Среднее
Fp1 - Fp2	87,33	90,48	33,25	50,28	46,05	-16,60	48,46
F7 - F8	90,01	92,33	19,28	31,68	1,46	-72,31	27,07
F3 - F4	80,43	92,80	32,14	32,63	24,03	-70,30	31,96
T3 - T4	94,27	92,39	25,04	45,65	19,72	-55,42	36,94
C3 - C4	86,04	91,91	42,53	48,90	47,14	-26,98	48,26
T5 - T6	88,10	91,01	17,42	53,83	15,28	-54,51	35,19
P3 - P4	84,33	90,80	36,04	58,25	41,45	-21,11	48,29
O1 - O2	79,40	87,15	42,81	40,53	45,56	28,16	53,93
Среднее	86,24	91,11	31,06	45,22	30,09	-36,13	-36,13

Таблица Б.4 – Результаты классификации для набора данных обнаружения эпилептиформ, процент правильной классификации

Итерация валидации	DWT-SVC	CSP-SVC	3DCNN-Holo	DWT-Tree	2DCNN-Hilbert
1	78,11	73,96	78,72	72,03	82,19
2	67,68	79,94	81,92	73,84	80,26
3	50,62	84,16	61,05	72,98	68,22
4	67,52	80,42	70,47	79,72	63,30
5	64,79	79,08	73,78	75,33	64,31
6	83,78	81,75	85,12	79,98	87,90
7	78,05	73,51	81,81	71,36	81,39
8	69,18	79,35	69,34	74,21	79,29
9	51,26	84,16	60,83	70,52	66,61
10	64,15	80,74	82,29	79,83	62,87
11	65,17	78,65	74,16	74,48	65,65
12	73,82	81,96	80,62	81,26	89,61
13	78,46	74,28	83,83	72,03	82,64
14	70,52	79,56	81,06	74,21	81,27
15	49,76	85,07	50,78	71,75	67,04
16	63,03	79,78	78,71	79,24	64,42
17	64,63	79,29	73,89	74,64	64,04
18	82,01	81,37	84,37	82,23	89,61
19	76,28	73,83	82,00	71,33	82,13
20	71,43	79,40	74,69	72,28	81,11
21	51,04	85,07	54,31	71,70	67,52
22	65,92	78,33	80,15	78,71	63,40
23	65,17	79,24	71,70	73,25	65,06
24	84,26	81,10	75,70	82,17	87,69

Таблица Б.5 – Результаты классификации для набора данных обнаружения эпилептиформ, процент правильной классификации

Итерация валидации	CSP-Forest	CSP-Tree	DWT-Forest	1DCNN-Hilbert	1DCNN-Holo
1	71,49	67,02	77,88	83,16	82,96
2	76,40	69,93	80,68	81,70	82,56
3	74,53	73,78	77,21	82,18	82,88
4	85,07	69,13	88,66	86,94	87,64
5	82,56	66,83	76,40	85,77	85,98
6	80,78	69,38	88,44	88,33	89,29
7	72,07	66,31	78,01	82,64	83,06
8	76,78	70,41	80,47	82,34	82,66
9	74,80	73,52	77,15	80,68	82,29
10	84,27	69,66	88,92	85,98	88,23
11	82,08	69,02	77,10	84,38	85,45
12	81,75	70,82	87,47	89,24	88,44
13	71,52	66,28	79,04	83,32	82,58
14	76,94	70,52	79,03	83,84	84,43
15	72,55	74,26	77,53	80,68	82,13
16	84,54	69,72	88,92	86,78	87,75
17	82,72	68,00	77,26	83,57	85,34
18	82,12	72,59	87,85	89,94	90,69
19	72,36	66,35	78,95	82,93	84,31
20	75,87	70,79	79,61	83,31	82,83
21	77,10	72,50	77,85	82,56	82,45
22	83,63	70,57	88,92	88,39	86,73
23	82,83	68,00	77,21	83,68	85,98
24	81,10	71,73	88,28	88,76	90,42

Приложение В

Свидетельства о государственной регистрации программ для ЭВМ

РОССИЙСКАЯ ФЕДЕРАЦИЯ



RU2021611177

ФЕДЕРАЛЬНАЯ СЛУЖБА
ПО ИНТЕЛЛЕКТУАЛЬНОЙ СОБСТВЕННОСТИ
ГОСУДАРСТВЕННАЯ РЕГИСТРАЦИЯ ПРОГРАММЫ ДЛЯ ЭВМ

<p>Номер регистрации (свидетельства): 2021611177</p> <p>Дата регистрации: 25.01.2021</p> <p>Номер и дата поступления заявки: 2021610374 19.01.2021</p> <p>Дата публикации и номер бюллетеня: 25.01.2021 Бюл. № 2</p> <p>Контактные реквизиты: нет</p>	<p>Автор(ы): Ходашинский Илья Александрович (RU), Сарин Константин Сергеевич (RU), Бардамова Марина Борисовна (RU), Светлаков Михаил Олегович (RU), Слезкин Артем Олегович (RU)</p> <p>Правообладатель(и): Федеральное государственное бюджетное образовательное учреждение высшего образования «Томский государственный университет систем управления и радиоэлектроники» (RU)</p>
---	---

Название программы для ЭВМ:

Программа извлечения пространственно-временных признаков из биометрических сигналов динамической рукописной подписи для аутентификации пользователя

Реферат:

Программа предназначена для создания вектора характеристических признаков сигналов рукописной подписи (получаемых с графического планшета) в биометрических системах аутентификации, использующих алгоритмы машинного обучения. Сто признаков формируются из пространственно-временных характеристик: времени нанесения подписи, количества пиков в сигналах подписи по координатам X и Y, среднего значения скорости и т.д. Программа разработана при финансовой поддержке Министерства образования и науки РФ в рамках научных проектов, выполняемых коллективами научных лабораторий образовательных организаций высшего образования, подведомственных Минобрнауки (№ FEWM-2020-0042). Тип ЭВМ: IBM PC-совмест. ПК; ОС: Windows 10.

Язык программирования: MATLAB

Объем программы для ЭВМ: 12,74 Кб

РОССИЙСКАЯ ФЕДЕРАЦИЯ



RU2022660268

ФЕДЕРАЛЬНАЯ СЛУЖБА
ПО ИНТЕЛЛЕКТУАЛЬНОЙ СОБСТВЕННОСТИ
ГОСУДАРСТВЕННАЯ РЕГИСТРАЦИЯ ПРОГРАММЫ ДЛЯ ЭВМ

Номер регистрации (свидетельства):
2022660268
Дата регистрации: 01.06.2022
Номер и дата поступления заявки:
2022618588 05.05.2022
Дата публикации и номер бюллетеня:
01.06.2022 Бюл. № 6
Контактные реквизиты:
ТУСУР, Аркатова О.Е., (3822) 70-15-83,
arkatova@main.tusur.ru

Автор(ы):
Ходашинский Илья Александрович (RU),
Сарин Константин Сергеевич (RU),
Бардамова Марина Борисовна (RU),
Светлаков Михаил Олегович (RU),
Слезкин Артем Олегович (RU)
Правообладатель(и):
Федеральное государственное бюджетное
образовательное учреждение высшего
образования «Томский государственный
университет систем управления и
радиоэлектроники» (RU)

Название программы для ЭВМ:

Программа генерации правил нечеткого классификатора на основе энтропийного алгоритма кластеризации k-means

Реферат:

Программа генерирует правила нечеткого классификатора на основе энтропийного алгоритма k-means. Алгоритм уменьшает число правил с максимального до указанного пользователем, либо пока ошибка классификации не достигнет порога. Также в процессе генерации автоматически производится отбор информативных признаков. Программа разработана при финансовой поддержке Министерства образования и науки РФ в рамках научных проектов, выполняемых коллективами научных лабораторий образовательных организаций высшего образования, подведомственных Минобрнауки Российской Федерации (№ FEWM-2020-0042). Тип ЭВМ: IBM PC-совмест. ПК; ОС: Windows 7/8/10.

Язык программирования: Python

Объем программы для ЭВМ: 9 Кб

РОССИЙСКАЯ ФЕДЕРАЦИЯ

**RU2022610117**

ФЕДЕРАЛЬНАЯ СЛУЖБА
ПО ИНТЕЛЛЕКТУАЛЬНОЙ СОБСТВЕННОСТИ
ГОСУДАРСТВЕННАЯ РЕГИСТРАЦИЯ ПРОГРАММЫ ДЛЯ ЭВМ

Номер регистрации (свидетельства):
2022610117

Дата регистрации: 10.01.2022

Номер и дата поступления заявки:
2021681630 24.12.2021

Дата публикации и номер бюллетеня:
10.01.2022 Бюл. № 1

Автор(ы):

Ходашинский Илья Александрович (RU),

Сарин Константин Сергеевич (RU),

Бардамова Марина Борисовна (RU),

Светлаков Михаил Олегович (RU),

Слезкин Артем Олегович (RU)

Правообладатель(и):

Федеральное государственное бюджетное

образовательное учреждение высшего

образования «Томский государственный

университет систем управления и

радиоэлектроники» (RU)

Название программы для ЭВМ:

Программа построения нечетких классификаторов диагностики онкологических заболеваний на основе дискретных метаэвристических алгоритмов

Реферат:

Программа предназначена для построения и оценки эффективности нечетких классификаторов диагностики онкологических заболеваний. Построение классификатора осуществляется дискретными генетическим алгоритмом и алгоритмом роящихся частиц. В качестве обучающих используются данные онкологических заболеваний. Программа разработана при финансовой поддержке Министерства образования и науки РФ в рамках научных проектов, выполняемых коллективами научных лабораторий образовательных организаций высшего образования, подведомственных Министерству науки и высшего образования Российской Федерации (№ FEWM-2020-0042). Тип ЭВМ: IBM PC-совмест. ПК. ОС: Windows 10.

Язык программирования: MATLAB

Объем программы для ЭВМ: 174 КБ

Приложение Г

Акт о внедрении результатов диссертационного исследования в рабочий процесс

ФМБА РОССИИ

ФГБУ ФНКЦ МРиК ФМБА России

«Томский научно-исследовательский институт курортологии и физиотерапии»
филиал Федерального государственного бюджетного учреждения
«Федеральный научно-клинический центр медицинской реабилитации и курортологии
Федерального медико-биологического агентства»
(Томский НИИКиФ)
ФФГБУ ФНКЦ МРиК ФМБА России)
634009, г. Томск, ул. Р. Люксембург, д. 1
Тел.: (3822) 512-005, Факс: (3822) 512-115
e-mail: niikf@niikf.tomsk.ru
ОКПО, ОГРН, 42294702, 1035008852944
ИНН/КПП 5044013246/701743001

УТВЕРЖДАЮ

Директор Томского НИИКиФ
ФФГБУ ФНКЦ МРиК ФМБА России

Зайцев А.А.

« 30 » *Зайцев* 2023 г.



АКТ О ВНЕДРЕНИИ

результатов диссертационной работы
на соискание ученой степени кандидата технических наук
Светлакова Михаила Олеговича

Комиссия в составе:

председатель Смирнова Ирина Николаевна,

члены комиссии: Алайцева Светлана Владимировна, Голосова Ольга Евгеньевна

составили настоящий акт о том, что результаты диссертационной работы Светлакова М. О. «Метод и алгоритмы анализа данных электроэнцефалографии для верификации субъекта» были внедрены в деятельность Томского «Научно-исследовательского института курортологии и физиотерапии» филиал Федерального государственного бюджетного учреждения «Федеральный научно-клинический центр медицинской реабилитации и курортологии Федерального медико-биологического агентства» и используются в повседневной практике.


Разработанное программное обеспечение используется для распознавания наличия/отсутствия эпилептиформ на сегментах электроэнцефалограммы, обработанных с помощью ПО ЭЭГ-исследования «Энцефалан-ЭЭГР» и полученных с помощью электроэнцефалографа-регистратора «Энцефалан-ЭЭГР-19/26». Программа позволяет на основе признаков, извлеченных «Энцефалан-ЭЭГР», и нечеткого классификатора подкрепить заключение врача о наличии/отсутствии эпилептиформы.

Разработанное программное обеспечение также используется в автоматическом режиме с использованием нейронных сетей, для распознавания наличия/отсутствия эпилептиформ на сегментах электроэнцефалограммы на основе файла формата edf без

необходимости ручного ввода значений признаков, что позволяет сократить процесс анализа 26-минутной записи ЭЭГ до 5 минут и повысить производительность труда врача функциональной диагностики.

Председатель комиссии:

Научный руководитель терапевтического отделения, д.м.н

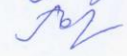
 Смирнова И.Н.

Члены комиссии:

Зав. отделением функциональной диагностики, к.м.н

 Алайцева С. В.

Ученый секретарь, к.м.н

 Голосова О. Е.

АКТ О ВЫПОЛНЕНИИ

обязанностей по выполнению работ

по проекту «...»

Составлены: ...

... ..

... ..

... ..

... ..

... ..

... ..

... ..

... ..

... ..

... ..

... ..

... ..

... ..

... ..

... ..

... ..

... ..

... ..

... ..

... ..

... ..

... ..

... ..

... ..

Приложение Д

Акт о внедрении результатов диссертационной работы в учебный процесс

Министерство науки и высшего образования Российской Федерации
Федеральное государственное бюджетное образовательное учреждение высшего образования
«ТОМСКИЙ ГОСУДАРСТВЕННЫЙ УНИВЕРСИТЕТ СИСТЕМ УПРАВЛЕНИЯ И
РАДИОЭЛЕКТРОНИКИ»



УТВЕРЖДАЮ

Проректор по учебной работе
канд. тех. наук, доцент

Сенченко П. Г.

« 03 » октября 2023 г.

И.о. ПРОРЕКТОРА ПО УР ДАРИОШИНА И.А.
ПО ПРИКАЗУ № 7395 ЛС ОТ 29.09.2023

АКТ

о внедрении в учебный процесс результатов диссертационной работы
на соискание ученой степени кандидата технических наук
Светлакова Михаила Олеговича

Комиссия в составе председателя Шурыгина Ю. А., заведующего кафедрой компьютерных систем в управлении и проектировании (КСУП), членов: Сарина К. С., доцента кафедры КСУП, Бардамовой М. Б., доцента кафедры КСУП, подтверждают, что результаты диссертационной работы Светлакова М. О. «Метод и алгоритмы анализа данных электроэнцефалографии для верификации субъекта» применяются в учебном процессе кафедры КСУП при организации занятий по дисциплинам «Проектирование микропроцессорных и компьютерных систем» при подготовке магистрантов по направлению.

Изучение возможностей применения метаэвристических алгоритмов для улучшения качества моделей машинного обучения, описанных Светлаковым М. О. в лабораторном занятии по методам искусственного интеллекта в рамках дисциплины «Проектирование микропроцессорных и компьютерных систем», позволяет студентам ознакомиться с применением метаэвристик для решения задач оптимизации и способствует развитию интереса магистрантов к проведению дальнейших исследований в области интеллектуальных систем.

В соавторстве с Ходашинским И. А. создано учебно-методическое пособие для выполнения практических и самостоятельных работ по дисциплине «Проектирование микропроцессорных и компьютерных систем». В пособие включены темы, затронутые в диссертационном исследовании и касающиеся использования метаэвристического алгоритма «стая птиц» для генерации базы правил, отбора признаков и оптимизации параметров нечеткого классификатора.

Материалы диссертации используются в научно-исследовательских работах других магистрантов и аспирантов кафедры КСУП.

Председатель комиссии

Члены комиссии

Шурыгин Ю. А.

Сарин К. С.

Бардамова М. Б.