


Министерство науки и высшего образования Российской Федерации
Федеральное государственное автономное образовательное учреждение
высшего образования

«Уральский федеральный университет
имени первого Президента России Б.Н. Ельцина»

Институт радиоэлектроники и информационных технологий - РТФ

Кафедра информационных технологий и систем управления


ДОПУСТИТЬ К ЗАЩИТЕ ПЕРЕД ГЭК

Зав. кафедрой ИТиСУ

_____ Е.В. Кислицын _____
(подпись) (Ф.И.О.)
« 03 » 06 2024 г.

ВЫПУСКНАЯ КВАЛИФИКАЦИОННАЯ РАБОТА

ИССЛЕДОВАНИЕ СИГНАЛОВ ЭЭГ ДЛЯ РАЗРАБОТКИ СИСТЕМЫ
РЕАБИЛИТАЦИИ С ИСПОЛЬЗОВАНИЕМ МЕТОДОВ МАШИННОГО
ОБУЧЕНИЯ

Научный руководитель: Борисов Василий Ильич
к.т.н., доцент


_____ подпись

_____ подпись

Нормоконтролер: Бредихина Наталья Сергеевна

Студент группы РИМ-220908: Калимуллина Алина Рафиковна


_____ подпись

Екатеринбург
2024

Министерство науки и высшего образования Российской Федерации
Федеральное государственное автономное образовательное учреждение высшего
образования
«Уральский федеральный университет
имени первого Президента России Б.Н. Ельцина»

Институт радиоэлектроники и информационных технологий - РТФ
Кафедра информационных технологий и систем управления
Направление подготовки 09.04.01 Информатика и вычислительная техника
Образовательная программа Инженерия искусственного интеллекта

ЗАДАНИЕ

на выполнение выпускной квалификационной работы

студента Калимуллиной Алины Рафиковны группы РИМ-220908
(фамилия, имя, отчество)

1. Тема выпускной квалификационной работы Исследование сигналов ЭЭГ для разработки системы реабилитации с использованием методов машинного обучения


Утверждена распоряжением по институту от «4» декабря 2023 г. № 33.02-05/298

2. Научный руководитель Борисов Василий Ильич, к.т.н., доцент
(Ф.И.О., должность, ученая степень, ученое звание)


3. Исходные данные к работе

4. Перечень демонстрационных материалов презентация в MS PowerPoint

5. Календарный план

№ п/п	Наименование этапов выполнения работы	Срок выполнения этапов работы	Отметка о выполнении
1.	Глава 1. Анализ предметной области	до 23.03.2024 г.	
2.	Глава 2. Методы и инструменты	до 29.04.2024 г.	
3.	ВКР в целом	до 20.05.2024 г.	

Научный руководитель


Ф.И.О.


(подпись)

Студент задание принял к исполнению 12.02.24
дата

(подпись)

6. Допустить Калимуллину Алину Рафиковну к защите выпускной квалификационной работы в экзаменационной комиссии

Зав. кафедрой ИТиСУ


(подпись)

Е.В. Кислицын
Ф.И.О.

РЕФЕРАТ

Калимуллина А.Р. Исследование сигналов ЭЭГ для разработки системы реабилитации с использованием методов машинного обучения.

Выпускная квалификационная работа содержит 72 страниц, 8 рисунков, 6 таблиц, 45 источников.

VR, ЭЭГ, КОГНИТИВНЫЕ НАРУШЕНИЯ, СИСТЕМА РЕАБИЛИТАЦИИ, НЕЙРОННЫЕ СЕТИ.

Объект исследования – биоэлектрическая активность мозга, регистрируемая 19-канальным энцефалографом в процессе когнитивной нагрузки в виртуальной среде.

Предмет исследования – количественные оценки когнитивных функций, полученные на основе анализа биосигналов с применением методов машинного обучения.

Цель работы – исследование оценки когнитивных функций на основе анализа биосигналов, применимой для задач нейрореабилитации.

Решены следующие задачи:

- 1) проведен анализ литературы и выбран инструментарий для проведения исследования;
- 2) проведен анализ известных наборов данных и собран собственный набор данных;
- 3) спроектирована модель когнитивной реабилитации с применением задачи БОС;
- 4) проверены модели для решения задачи классификации.

СОДЕРЖАНИЕ

ВВЕДЕНИЕ.....	7
1. Анализ предметной области	10
1.1 Основы электроэнцефалографии (ЭЭГ)	10
1.2 Машинное обучение в когнитивной реабилитации	16
1.3 Виртуальная реальность для нейрореабилитации.....	21
1.4 Расположение электродов на голове	23
1.5 Выводы по 1 главе	25
2. Методы и инструменты	27
1.6 Описание общедоступных баз данных	27
1.7 Материалы и методы снятия сигналов ЭЭГ	29
1.8 Примеры обработки сигналов ЭЭГ на общедоступном наборе данных	32
1.8.1 ShallowFBCSPNet на общедоступном наборе данных	32
1.8.2 Deep4Net на общедоступном наборе данных	36
1.8.3 EEGConformer на общедоступном наборе данных	38
1.8.4 SVM на общедоступном наборе данных.....	40
1.8.5 RandomForestClassifier на общедоступном наборе данных	43
1.8.6 KNeighborsClassifier на общедоступном наборе данных ...	45
1.9 Примеры обработки сигналов ЭЭГ на собранном наборе данных	48
1.9.1 ShallowFBCSPNet на собранном наборе данных	48
1.9.2 Deep4Net на собранном наборе данных	49
1.9.3 EEGConformer на собранном наборе данных	50
1.9.4 SVM на собранном наборе данных.....	51
1.9.5 RandomForestClassifier на собранном наборе данных	52

1.9.6 KneighborsClassifier на собранном наборе данных	53
3. Обсуждение результатов.....	55
2.1 Модели глубокого обучения.....	55
2.2 Классические модели машинного обучения.....	58
ЗАКЛЮЧЕНИЕ	63
СПИСОК ИСПОЛЬЗОВАННЫХ ИСТОЧНИКОВ	66

СПИСОК СОКРАЩЕНИЙ

VR (Virtual Reality) – виртуальная реальность
AR (Augmented Reality) – дополненная реальность
BCI (Brain-computer interface) – мозг-компьютерный интерфейс
CNN (Convolutional neural network) – сверточная нейронная сеть
RNN (Recurrent neural network) – рекуррентная нейронная сеть
SVM (support vector machine) – метод опорных векторов
MLP (Multilayer perceptron) – многослойный перцептрон
MR (Mixed Reality) – смешанная реальность
ML (Machine Learning) – машинное обучение
DL (Deep Learning) – глубокое обучение
ЭЭГ – электроэнцефалография
ЦНС – центральная нервная система
ФР – функция распределения
ФВЧ – фильтр высоких частот
ФНЧ – фильтр низких частот
ВР – временные ряды
ПО – программное обеспечение
ОБС – обратная биологическая связь
ФС – функциональное состояние

ВВЕДЕНИЕ

Когнитивные нарушения, возникающие в результате неврологических заболеваний, таких как инсульт, черепно-мозговая травма и нейродегенеративные заболевания, создают серьезные проблемы для пострадавших людей и их окружения. Эти нарушения могут влиять на внимание, память, исполнительные функции, речь и функциональные жизненные навыки, которые постепенно ухудшаются вследствие когнитивных нарушений. Традиционные подходы к когнитивной реабилитации основываются на упражнениях с бумагой и ручкой, при таком подходе может не хватать вовлеченности пациента и актуальности тестов для эффективного восстановления.

Необходимость разработки новых методов когнитивной реабилитации становится все более актуальной в контексте усиления проблем, связанных с демографическими изменениями, ускорением темпа жизни и повышением требований к когнитивному статусу.

По статистике, численность населения с нарушением когнитивных функций растет во всем мире. В России прирост заболеваемости ментальными расстройствами за последние три года составил около 10%. Частота депрессий в популяции течение жизни составляет 25%. Согласно прогнозам ВОЗ, к 2030 году депрессия выйдет на первое место по причине нетрудоспособности. Также исследовательская компания Ipsos привела данные после исследования своих сотрудников, согласно которым 24% опрошенных испытывают проблемы с тревогой и беспокойством, 38% испытывают депрессивные настроения, 26% работают под большим давлением коллег и начальства и 12% работают более 8 часов в день [1].

Вышеуказанная демографическая и эпидемиологическая ситуация делает проблему реабилитации неврологических больных, а именно

реабилитации когнитивных способностей как основного фактора потери трудоспособности, особенно актуальной. Несмотря на то, что часть городского населения увеличивается, количество людей, проживающих в пригородах или более отдаленных пунктах, остается практически неизменным. В данной группе особенно сложно организовать реабилитационные мероприятия, поскольку необходимо присутствие врача и наличие необходимого оборудования [2].

В связи с распространением инновационных информационно-коммуникационных технологий на первый план в организации и функционировании дистанционной медицинской реабилитации выходят современные технологии, такие как: виртуальная реальность (VR), дополненная реальность (AR) и смешанная реальность (MR). Использование современных методов позволяют создать более эффективные системы реабилитации, способные учитывать индивидуальные способности каждого пациента, улучшать эффективность процесса восстановления и повысить качество жизни людей с когнитивными нарушениями. Кроме того, виртуальная реальность позволяет учитывать эмоции пациента, его двигательные функции и различные органы чувств. Использование виртуальной реальности и биологической обратной связи, например ЭЭГ, позволяет проводить тренировки или реабилитационные мероприятия для пациентов, страдающих нарушениями когнитивных функций.

Под реабилитацией с использованием методов машинного обучения подразумевается система, в которой с помощью алгоритмов машинного обучения анализируются и выявляются важные зависимости между переменными в собираемых данных. Это позволяет выявлять закономерности, которые могут быть использованы для формирования гипотез и предложений для построения оптимального плана реабилитации пациента. Такой подход позволит сократить время, необходимое для анализа данных, уменьшить

количество ошибок, связанных с человеческим фактором, а также поспособствует повышению качества оценки интерпретации врачом.

Отсюда следует актуальность исследования сигналов электроэнцефалографии (ЭЭГ) для разработки системы реабилитации на основе методов машинного обучения. Интеграция современных технологий в процесс реабилитации значительно сократит время необходимое для восстановления пациента и способствует улучшению результатов лечения. Развитие систем реабилитации на основе анализа сигналов ЭЭГ и методов машинного обучения является перспективным направлением в медицине.

Цель работы – исследование оценки когнитивных функций на основе анализа биосигналов, применимой для задач нейрореабилитации.

Поставлены следующие задачи:

- 1) провести анализ литературы и выбрать инструментарий для проведения исследования;
- 2) провести анализ известных наборов данных и собрать собственный набор данных;
- 3) спроектировать модель когнитивной реабилитации с применением задачи БОС;
- 4) проверить модели для решения задачи классификации.

1. Анализ предметной области

1.1 Основы электроэнцефалографии (ЭЭГ)

Электроэнцефалограмма (ЭЭГ) представляет собой запись биоэлектрической активности мозга. Главными частями головного мозга являются: кора головного мозга, мозжечок, ствол мозга (включающий средний мозг, продолговатый мозг и ретикулярное образование) и таламус (между средним мозгом и полусферами) [3]. Сигнал ЭЭГ используется для изучения нервной системы, мониторинга стадий сна, биологической обратной связи и управления, а также диагностики неврологических и психических заболеваний.

Регистрация сигналов ЭЭГ производится при помощи электроэнцефалографа «Нейрон-спектр-3» через специальные электроды, где каждый электрод подключен к усилителю. Запись потенциалов каждого электрода осуществляется относительно нулевого потенциала, за который обычно принимаются мочки ушей.

«Нейрон-спектр-3» представляет из себя 19-канальный электроэнцефалограф для ЭЭГ исследований с высокой частотой квантования (до 5000 Гц). Такая частота позволяет регистрировать высокочастотные составляющие сигнала без резкого снижения амплитуды. Низкий уровень амплитуды способствует применению самой щадящей фильтрации ЭЭГ или не проведению фильтрации вообще, что позволяет максимально сохранять полезную информацию в исходном сигнале. 19-канальный электроэнцефалограф представлен на Рисунке 1 – «19-канальный электроэнцефалограф Нейрон-спектр-3».




Рисунок 1 –19-канальный электроэнцефалограф «Нейрон-спектр-3» [17]

При анализе сигналов ЭЭГ обычно используются следующие диапазоны частот:

1) $0,5 < f < 4$ Гц – дельта-ритм (δ), состоящий из волн амплитудой до сотни мкВ. Дельта-ритм возникает как при глубоком естественном сне, так и при наркотическом, а также при коме. Дельта-ритм также наблюдается при регистрации ЭЭГ от участков коры, граничащих с областью травматического очага или опухоли;

2) $4 < f < 8$ Гц – тета-ритм (θ), характеризует высокий электрический потенциал – 100–150 мкВ, высокую амплитуду волн. Наиболее ярко тета-ритм обычно выражен у детей от 2 до 8 лет;

3) $8 < f < 13$ Гц– альфа-ритм (α): средняя амплитуда – 30–70 мкВ, могут наблюдаться как высоко- и низкоамплитудные α -волны. Регистрируется у 85–95% здоровых взрослых. Лучше всего альфа-сигнал выражен в затылочной области;

4) $13 < f < 30$ Гц – бета-ритм (β), в состоянии активного бодрствования имеет напряжение – 5–30 мкВ. Наиболее сильно бета-ритм выражен в лобной области, но при различных видах интенсивной деятельности резко усиливается и может распространяться на другие области головного мозга. Бета-волны по форме близки к треугольным вследствие заостренности вершин;

5) $30 < f < 120$ Гц – гамма-ритм (γ), частота в некоторых случаях может достигать 500 Гц, амплитуда ниже 10 мкВ, и обратно пропорциональна частоте. В случае если амплитуда гамма-ритма выше 15 мкВ, то ЭЭГ рассматривается как паталогическая. Гамма-ритм наблюдается при решении задач, требующих максимального сосредоточенного внимания;

После определения частоты, обычно определяется размах колебаний электрического потенциала. Измеряется расстояние между пиками волн в противоположных фазах и выражается в микровольтах (мкВ).

Для измерения амплитуды применяется калибровочный сигнал, называемый амплитудой. Амплитуда в электроэнцефалограмме является одним из основных показателей и представляет собой значение разности потенциалов между двумя точками на электроде. Амплитуда сигналов ЭЭГ может иметь различные характеристики и описывать разные аспекты электрической активности головного мозга. Например:

1) амплитуда базового уровня – представляет собой небольшую амплитуду, которую можно наблюдать в состоянии покоя мозга или при выполнении некоторых базовых функций. Амплитуда базового уровня обычно составляет несколько микровольт;

2) амплитуда эвокированных потенциалов – представляет собой амплитуду, возникающую в ответ на стимуляцию, такую как звуковые или световые сигналы. Амплитуда эвокированных потенциалов может быть больше базового уровня и достигать нескольких сотен микровольт;

3) амплитуда ритмических колебаний – возникает, когда мозг генерирует различные ритмические колебания, такие как альфа-, бета-, тета- и дельта-ритмы. Амплитуда ритмических колебаний может быть разной в зависимости от состояния мозга. Например, в состоянии сонливости амплитуда альфа-ритма может быть выше, чем в состоянии бодрствования;

4) амплитуда эпилептических разрядов – возникает при эпилептических приступах. Мозг может генерировать сильные электрические разряды, которые имеют очень высокую амплитуду. Это может быть признаком эпилепсии.

Амплитуда в ЭЭГ является важным показателем для диагностики и изучения состояния мозга. Она может изменяться в зависимости от возраста, состояния пациента, наличия патологий и других факторов.

Признаки – это характеристики сигналов головного мозга, с помощью которых можно оценить функциональное состояние человека.

Под характеристикой сигналов понимают характеристики временных рядов, которые получают в процессе регистрации сигналов головного мозга. Такие временные ряды являются реализацией случайных шумоподобных процессов, которые могут обладать характеристиками стационарности на небольших участках, выделяющихся в сигнале. В ЭЭГ такие участки называются эпохами. Также эпохами называют предварительно отобранные повторяющиеся участки эксперимента.

Обычно, выделяют 2 фактора, с которыми связана шумоподобная природа сигнала:

- особенности формирования сигнала головного мозга на поверхности головы;
- сигналы, регистрируемые на поверхности головы, но не связанные с наблюдаемыми процессами головного мозга.

При помощи источников внутри головного мозга на поверхности головы формируются потенциалы. Группы нейронов, начиная работать синхронно,

образуют электрический диполь. В головном мозге может быть несколько источников тока одновременно, число и ориентация таких диполей со временем меняется. Такой эффект называется эффектом объемной проводимости, который приводит к тому, что на поверхности головы в месте расположения электрода получается сложная сумма токов множества диполей. Также, электроэнцефалографом регистрируются потенциалы, связанные с работой электрической сети и электрических приборов, а также потенциалы, связанные с работой сердца, движением глазного яблока, электрической активностью мышц и шеи лица.

Поскольку электроэнцефалограф регистрирует множество потенциалов, необходима фильтрация сигнала ЭЭГ. Фильтрация является одним из основных методов обработки данного типа сигнала. С помощью фильтрации удаляются артефакты и шумы, которые могут присутствовать в сигнале, тем самым улучшается качество для дальнейшего анализа. При этом есть необходимость понимать, что неправильное применение фильтрации может привести к значительным искажениям информативной составляющей сигнала.

Прежде чем применить фильтрацию сигнала на начальном этапе необходимо выполнить следующие действия:

- 1) провести визуальный анализ исходных сигналов и составить перечень возможных источников шума, оценить интенсивность;
- 2) определить каковы информативная и шумовая составляющая сигнала с точки зрения частотных составляющих, насколько пересекаются;
- 3) понять влияние фильтрации на полезные характеристики сигнала, например, на амплитуду вызванного потенциала, временные параметры вызванного потенциала;
- 4) уточнить влияние шума в сигнале на применяемые методы анализа.

Артефакты, как и шумы, могут быть возникать в сигнале ЭЭГ и мешать правильному анализу [24, 26, 28, 37]. Артефакты могут быть вызваны

различными факторами, например, электромагнитные помехи, движения пациента, мускульная активность и другие внешние воздействия. Некоторые из наиболее распространенных артефактов ЭЭГ включают в себя:

1) артефакты движения, возникающие вследствие движений головы или тела испытуемого во время записи ЭЭГ. Такие артефакты могут проявляться в виде быстрых изменений амплитуды или частоты сигнала;

2) артефакты мышечной активности, возникающие вследствие сокращений мышц головы и шеи испытуемого. Такие артефакты обычно имеют высокую амплитуду и проявляются в виде резких пиков или шумов;

3) артефакты электромагнитных помех, возникающие вследствие воздействия внешних источников электромагнитных полей, таких как электронные устройства или электрические провода. Такие артефакты могут проявляться в виде низкочастотных помех или резких изменений амплитуды;

4) артефакты сети, возникающие вследствие синхронной активности множества нейронных популяций в мозге, вызванная электрической активностью сети электродов ЭЭГ. Такие артефакты обычно имеют низкую частоты и проявляются в виде регулярных колебаний или шумов.

Распознавание эмоций по сигналам ЭЭГ – сложная и ответственная задача, прежде всего потому, что сигналы ЭЭГ записываются по различным каналам, а процесс их получения часто занимает много времени [6]. Кроме того, сигналы ЭЭГ восприимчивы как к внутренним, так и к внешним шумам, вследствие чего врачу сложно определить эмоции, которые испытывал человек [43, 44].

Поскольку целью работы является разработка системы оценки когнитивных функций на основе анализа биосигналов ЭЭГ, необходимо провести анализ существующих решений для задач нейрореабилитации.

1.2 Машинное обучение в когнитивной реабилитации

Традиционные методы машинного обучения (ML) являются основными подходами, используемыми для расширения методов распознавания психофункционального состояния человека на основе ЭЭГ. Эти методы включают в себя извлечение временных, частотных и нелинейных характеристик предварительно обработанных сигналов ЭЭГ. Подходы машинного обучения включают четыре ключевых этапа: предварительную обработку, извлечение признаков, выбор признаков (уменьшение размерности) и классификацию [45, 25, 28, 31].

В работе, выбранной для анализа [8], рассматривается набор данных emotions.csv, доступный на сайте Kaggle [7]. Это данные размером 48,83 МБ. Набор данных содержит 2132 строки и 2549 столбцов. Первые 2548 столбцов содержат независимые атрибуты, такие как среднее значение, стандартное отклонение, энтропия, преобразование Фурье и т. д., извлеченные из данных биосигналов ЭЭГ. Последний столбец представляет собой зависимый атрибут с именем label, содержащий три класса: Negative:0, Neutral:1, Positive:2. Набор данных содержит 716 нейтральных значений (1), тогда как положительные и отрицательные классы содержат по 708.

Рассмотрим наиболее популярные методы машинного обучения (ML) и глубокого обучения (DL), а именно: CNN, RNN, SVM и MLP. Эти методы успешно используются в качестве классификаторов для решения схожих задач.

MLP: Многослойный персептрон представляет собой дополнение нейронной сети с прямой связью. MLP имеет три слоя: входной слой, скрытый слой и выходной слой.

Входной слой принимает сигнал для обработки. Выходной слой отвечает за такие функции как классификация и прогнозирование. Непосредственно связанный механизм MLP представляет собой бесконечную серию скрытых

слоев, расположенных между выходными и входными слоями. Данные передаются по прямому пути от входа к выходному слою в MLP, что эквивалентно сети в режиме прямой связи.

Метод обучения обратного распространения ошибки используется для обучения всех узлов MLP. С помощью MLP можно решить проблемы, которые не являются линейно разделимыми и структурированы с учетом аппроксимации каждой непрерывной функции [9].

CNN: Архитектура CNN или ConvNets обычно состоит из трех типов слоев (или строительных блоков): свертки, объединения и полностью связанных слоев.

Первые два слоя – слои свертки и объединения, выполняют извлечение признаков, а третий слой (полностью связанный слой) отображает извлеченные признаки в конечный результат, например классификацию. Слой свертки в CNN состоит из набора математических операций, таких как свертка, специализированный тип линейной операции. В цифровых изображениях значения пикселей хранятся в двумерной 2D – сетке, т.е. в массиве чисел, а в каждой позиции изображения применяется небольшая сетка параметров, называемая ядром, оптимизируемым экстрактором признаков, что делает CNN высокоэффективными для обработки изображений. По мере того, как один слой передает свои входные данные в следующий слой, извлеченные объекты могут иерархически и постепенно усложняться.

Процесс оптимизации параметров, таких как ядра, называется обучением. Обучение выполняется таким образом, чтобы минимизировать разницу между входными данными и истинными значениями, с помощью алгоритма оптимизации, называемого обратным распространением ошибки и градиентным спуском [10, 40, 44].

RNN: Использует последовательные данные или данные временных рядов. Ключевой особенностью *RNN* является способность сохранять

информацию из предыдущих входных данных и использовать ее для информирования последующих входных и выходных данных во время обучения последовательности [11, 20].

SVM: Алгоритм машинного обучения, который использует модели обучения с учителем для решения задач классификации, регрессии и обнаружения выбросов путем выполнения оптимальных преобразований данных, которые определяют границы между точками данных на основе заранее определенных классов, меток или входных данных. Технически цель алгоритма SVM – определить гиперплоскость, которая четко разделяет точки данных разных классов. Гиперплоскость локализована таким образом, что рассматриваемые классы разделяет наибольший запас [12, 21, 30].

Были применены три различные архитектуры глубокого обучения: MLP, CNN, RNN и один контролируемый метод машинного обучения SVM на данных emotions.csv, чтобы сравнить эффективность этих моделей для отслеживания психофункционального состояния человека по данным мозговых волн ЭЭГ. Для реализации алгоритмов использовался язык программирования Python.

Производительность и пригодность этих моделей были исследованы путем сохранения 20%, 30% и 40% данных в тестовом наборе. В таблице 1 – «Точность моделей на обучающих данных» представлена производительность обучающего набора различных нейронных сетей и архитектуры машинного обучения в процентах (%), полученная при реализации моделей с сохранением 20%, 30% и 40% данных в тестовом наборе.

Таблица 1 – Точность моделей на обучающих данных [8]

Процент данных в тестовом наборе	MLP (%)	CNN (%)	RNN (%)	SVM (%)
20%	83,20	97,36	97,95	100,0
30%	84,28	97,36	97,32	100,0
40%	84,77	97,27	97,27	100,0

Из Таблицы 1 – «Точность моделей на обучающих данных» можно заметить, что показатели распознавания архитектуры MLP составляют 83,20%, 84,28% и 84,77% соответственно с сохранением 20%, 30% и 40% данных в тестовом наборе. Архитектура CNN составляет 97,36%, 97,36% и 97,27% соответственно. Архитектура RNN составляет 97,95%, 97,32% и 97,27%. Можно заметить, что распознавание обучающего набора данных составляет 100% для метода машинного обучения *SVM*. Оно осталось инвариантным (100%) для всех трех комбинаций, в то время как архитектуры глубоких нейронных сетей показали результаты чуть хуже.

В Таблице 2 – «Точность моделей на тестовых данных» представлены показатели распознавания тестового набора различных нейронных сетей и архитектуры машинного обучения в процентах (%), полученная при реализации моделей с сохранением 20%, 30% и 40% данных в тестовом наборе.

Таблица 2 – Точность моделей на тестовых данных [8]

Процент данных в тестовом наборе	MLP (%)	CNN (%)	RNN (%)	SVM (%)
20%	77,37	59,25	97,95	97,65
30%	75,93	56,40	96,40	97,18
40%	76,43	49,82	93,90	95,89

Из Таблицы 2 – «Точность моделей на тестовых данных» можно заметить, что показатели архитектуры RNN составляют 97,95%, 96,40% и 93,90%. Архитектура RNN показала хорошие результаты на этапах обучения и тестирования. Среди нейронных сетей модель RNN признана наиболее подходящей для определения психофункционального состояния человека по сигналам ЭЭГ.

Архитектура классического машинного обучения SVM превзошли результаты как на этапе обучения, так и на этапе тестирования, показатели составили 97.65%, 97.18% и 95,89% при 20%, 30% и 40% данных соответственно. Среди архитектур контролируемого машинного обучения SVM признана наиболее подходящей для последовательных данных и данных временных рядов. Следовательно, SVM оказалась наиболее подходящей архитектурой контролируемого машинного обучения для отслеживания психофункционального состояния человека.

Результаты, полученные при реализации архитектуры MLP, носят умеренный характер, как на этапе обучения, так и на этапе тестирования. Архитектура CNN в свою очередь показала низкие результаты, особенно на этапе тестирования. Архитектура CNN лучше всего подходит для данных в виде изображений. Как правило, модели контролируемого машинного обучения хорошо работают в случае последовательных данных, данных с линейным разделением и временных рядов. Реализация архитектуры SVM показала лучшие результаты, как на этапе обучения, так и на этапе тестирования. Можно сделать вывод, что архитектуру RNN и архитектуру SVM можно рассматривать как подходящие модели для отслеживания психофункционального состояния человека по данным мозговых волн ЭЭГ.

При регистрации сигналов ЭЭГ необходимо проводить моделирование нагрузок для того, чтобы оценить изменение психофункционального

состояния человека. Одним из примеров таких нагрузок является виртуальная реальность.

1.3 Виртуальная реальность для нейрореабилитации

Травма головного мозга – серьезное заболевание, которое нарушает нормальное функционирование мозга и серьезно влияет на жизнь человека. Двумя основными причинами повреждения головного мозга являются: механическая травма, которая является наиболее распространенным типом черепно-мозговой травмы, и сосудистые нарушения [13]. Черепно-мозговая травма и инсульт приводят к когнитивным, неврологическим и психическим нарушениям, которые можно частично восстановить с помощью нейрореабилитации. Наиболее распространенными видами нарушения когнитивных функций у человека являются:

- 1) паралич или нарушение двигательного контроля;
- 2) сенсорные нарушения, включая боль;
- 3) нарушение мышления и памяти;
- 4) нарушение речи и понимания;
- 5) эмоциональные расстройства, включая чувство страха, тревоги разочарования или печали.

Знание анатомии коры головного мозга необходимо для точного описания локализации когнитивных функций и правильного понимания локализованного характера наблюдаемых изменений объемов серого вещества или спектров мощности ЭЭГ после воздействия виртуальной реальности.

Структурно головной мозг состоит из двух полушарий головного мозга, обозначаемых соответственно, как левое и правое. Кора разделена большими бороздками на четыре доли: лобную долю, височную долю, теменную долю и затылочную долю. Каждая доля содержит гребни, называемые извилинами,

специализирующиеся на выполнении определенных когнитивных функций. Разберем за какие функции отвечает каждая доля.

Лобная доля. Лобная доля расположена в передней части головы. В приложениях VR активно участвует в рабочей памяти и управлении моторикой [15]. Прокентральная извилина содержит первичную моторную кору, которая осуществляет контроль над произвольными движениями посредством стимуляции сокращения скелетных мышц. Верхняя лобная извилина отвечает за генерацию смеха. Средняя лобная извилина способствует поддержанию информации в сознании. Нижняя лобная извилина доминантного полушария содержит зону Брока, которая контролирует речь. Поясная извилина участвует в сенсорном восприятии боли.

Височная доля. Височная доля расположена сбоку головы над ухом. В VR- приложениях активно участвует в семантической обработке информации и эпизодической памяти [16]. В верхней височной извилине находится зона, необходимая для понимания письменной и устной речи. Средняя височная доля участвует в распознавании звуков, семантическом поиске, семантической памяти и обработке речи. Нижняя височная извилина способствует выполнению задач по запоминанию слов.

Теменная доля. Теменная доля расположена в средне-верхней части головы над височной долей. В VR- приложениях активно участвует в создании ощущения присутствия [16]. Постцентральная извилина содержит первичную соматосенсорную кору, генерирующую соматические ощущения и чувство воплощения. Верхняя теменная доля участвует в зрительном воображении, психических трансформациях тела в пространстве и регуляции эмоций. Угловая извилина играет роль в умственных вычислениях, кодировании и извлечении связанных со схемой воспоминаний и воображения. Предклинье способствует формированию зрительно-пространственных образов,

извлечению эпизодических воспоминаний и операциям самообработки, таким как взгляд от первого лица.

Затылочная доля. Затылочная доля расположена в задней части головы. В VR- приложениях активно участвует в создании визуальных образов. Первичная зрительная кора отвечает за зрение и зрительную информацию, получаемую от сетчатки. Язычная извилина играет важную роль в процессе чтения, а именно идентификации и распознавании слов. Верхняя, средняя и нижняя затылочные извилины содержат зрительные ассоциативные коры, которые интерпретируют и придают дополнительное значение зрительным сигналам.

Таким образом, использование технологии VR в когнитивной реабилитации позволяет воспроизводимо и объективно оценивать когнитивные процессы, лежащие в основе внимания, памяти, обработки информации и логической последовательности. В современных научных публикация VR является одним из наиболее популярных методов нейрореабилитации на сегодняшний день. Поскольку обучение на основе виртуальной реальности хорошо воспринимается пациентами и продемонстрировало обнадеживающее улучшение когнитивных показателей, которые зависят от функциональных лобных долей. Считается, что значительные улучшения в реабилитации после программы упражнений VR связаны с изменением в пластичности нейронов, которые улучшают рабочую память [14].

1.4 Расположение электродов на голове

Международная система 10–20 – это признанный во всем мире метод расположения электродов на коже головы при проведении исследования ЭЭГ. Свое название система получила благодаря тому, что расстояние от любого

электрода до соседнего определяется как 10% или 20% индивидуально измеренных размеров головы [18]. На рисунке 2 – «Схема расположения электродов по системе 10-20 для ЭЭГ» представлена схема расположения электродов 10–20 для ЭЭГ.




Рисунок 2 – Схема расположения электродов по системе 10–20 для ЭЭГ [18]

Название электродов включают первую букву латинского названия области, на которую ставится электрод, и номер, указывающий стороны и расположения электрода в пределах этой области:

- Fp1, Fp2 – переднелобные (prefrontal),
- F3, F4 – лобные (frontal),
- Fz – среднелобный,
- C3, C4 – центральные (central),
- Cz – центральный вертексный,
- P3, P4 – теменные (parietal),

- Pz – центральнотеменной,
- F7, F8 – передневисочные,
- T3, T4 – средневисочные (temporal),
- T5, T6 – задневисочные,
- O1, O2 – затылочная (occipital),
- A1, A2 – ушные.

Нечетные номера указывают на левое полушарие, четные на правое. Требуется минимум три отведения ЭЭГ для того, чтобы оценить активность с фронтальной, центральной и затылочной областей:

- рекомендуемые: F3-M2, C3-M2, O1-M2;
- резервные: F4-M1, C4-M2, O2-M1.

Необходимо минимум три отведения ЭЭГ, поскольку F4-M1 – лучшие для медленных волн (0,5–2,0 Гц), C4-M1 – лучшие для веретен 11–16 Гц (наиболее распространенные 12–14 Гц), O2-M1 – для альфа-ритма (8-13 Гц).

1.5 Выводы по 1 главе

Во время проведения исследования сигналов ЭЭГ для разработки системы реабилитации с использованием методов машинного обучения был выявлен ряд проблем.

Хотя литературы по BCI (мозг-компьютерному интерфейсу) на основе ЭЭГ достаточно много, однако оценка и интерпретация результатов сигналов электроэнцефалограммы остается серьезной проблемой для BCI.

Действительно, во многих исследованиях очень сложно, если вообще возможно, сравнить полученные результаты. Это связано с тем, что сравнению экспериментальных результатов препятствуют различные факторы:

- предварительная обработка данных;
- выборочные наборы данных;

– субъекты или классы в наборе данных;

С другой стороны, эта проблема усложняется потребностью в общих ресурсах и всесторонних оценках. Тщательные оценки зачастую выходят за рамки одной исследовательской работы, и поэтому крайне важно найти строгие методы для оценки производительности конвейеров *BCI* и обеспечить воспроизводимость этих результатов.

Исследование *BCI* включают в себя сложные методологии, сложные методы сбора данных и многогранные конвейеры анализа, что усложняет воспроизведение и проверку экспериментов.

Метаанализ – статистический метод объединения результатов нескольких исследований является мощным инструментом для обобщения результатов и получения информации от большего количества исследователей. Однако из-за не стандартизованных протоколов оценки проведение метаанализа в области *BCI* весьма затруднительны. Изменчивость наборов данных, экспериментальных задач затрудняют получения полного представления о работе *BCI*.

2. Методы и инструменты

1.6 Описание общедоступных баз данных

В данном разделе проведен поиск существующих наборов данных, а также описан метод снятия биосигналов для собственного набора данных сигналов ЭЭГ. Ниже представлены существующие наборы данных с записями сигналов ЭЭГ.

CHB-MIT Scalp EEG Database v1.0.0 [19]. В наборе данных содержатся данные ЭЭГ, собранные у пациентов с эпилепсией по международной системе 10–20. В съеме сигналов участвуют 5 мужчин (от 3 до 22 лет) и 17 женщин (от 1,5 лет до 19 лет). Метод исследования заключался в том, что участникам отменили противосудорожные препараты и наблюдали за субъектами в течение нескольких дней. Датасет содержит 664 файла расширения .edf. Записи сгруппированы в 23 случая. Каждый случай содержит от 9 до 42 непрерывных файла.

EEG During Mental Arithmetic Tasks v1.0.0 [20]. В датасете содержатся данные ЭЭГ, собранные во время выполнения участниками задач по ментальной арифметике. В съеме сигналов участвуют 24 человека (группа «Г») и 12 человек (группа «Б»). В Группе «Г» находятся люди, выполняющие подсчет хорошего качества, в группе «Б» - подсчет плохого качества. Метод исследования заключался в том, что участники выполняли арифметические задачи по последовательному вычитанию двух чисел. Данные записывались с фильтром верхних частот, с частотой среза 30 Гц. Все записи ЭЭГ представляют собой сегменты ЭЭГ без артефактов, длительностью 60 секунд. Данные содержат запись фоновой ЭЭГ субъекта и запись ЭЭГ во время выполнения задачи по ментальной арифметике. Данные сняты по международной системе 10 – 20 и хранятся в формате .edf.

ZuCo 2.0: A Dataset of Physiological Recordings During Natural Reading and Annotation [21]. В датасете содержатся данные ЭЭГ, собранные во время естественного чтения и аннотации текстов. В съеме сигналов участвуют 12 здоровых взрослых (5 женщин и 7 мужчин) в возрасте от 22 лет до 54 лет. Метод исследования заключался в том, что необходимо пройти 3 испытания. В 1 испытании предлагались положительные, отрицательные или нейтральные предложения для обычного чтения. Во 2 испытании предлагались предложения, содержащие смысловые связи. В 3 испытании предлагались те же предложения, что и во втором испытании, но с конкретными инструкциями. Данные ЭЭГ записывались с частотой дискретизации 500 Гц и полосой пропускания от 0,1 Гц до 100 Гц с использованием 128-канальной системы ЭЭГ.

Sleep-EDF Database Expanded [22]. В датасете содержатся данные ЭЭГ, ЭОГ, ЭМГ, собранные во время сна на протяжении всей ночи. База данных включает 61 ночную полисомнограмму здоровых субъектов и субъектов с легкими трудностями засыпания. Файлы содержатся в формате PSG.edf и представляют собой полисомнографические записи сна, содержащие ЭЭГ (из мест расположения электродов Fpz-Cz и Pz-Oz), т.е. передней центральной области головы и задней парието-окципитальной части головы.

BCIC IV 2a [23]. В датасете содержатся данные ЭЭГ от 9 субъектов. Парадигма BCI, основанная на различных задачах двигательного воображения, а именно: движение левой руки (1 класс), правой руки (класс 2), движение ног (3 класс) и языка (4 класс). Каждая запись состоит из 6 тренировок, разделенными короткими перерывами. Один цикл состоит из 48 попыток (по 12 каждого из четырех возможных классов), что дает в общей сложности 288 попыток за 1 цикл. Для регистрации ЭЭГ использовались 22 Ag/agCl-электрода (с межэлектродным расстоянием 3,5 см). Сигналы дискретизировались с частотой 250 Гц и подвергались полосовой фильтрации

в диапазоне от 0,5 Гц до 100 Гц. Чувствительность усилителя была установлена на уровне 100 мкВ. Для подавления линейного шума был включен дополнительный режекторный фильтр.

После анализа общедоступных наборов данных, при составлении собственного набора данных особое внимание было обращено на методы снятия сигналов. Все сигналы ЭЭГ были собраны во время выполнения различных задач и в определенных контекстах (например, координация, проверка памяти или покой). Такие данные позволяют изучить активность мозга под разными нагрузками и понять, какие паттерны активности могут быть связаны с определенными процессами или состояниями.

1.7 Материалы и методы снятия сигналов ЭЭГ

Для проверки гипотезы о том, что по сигналам ЭЭГ можно различать когнитивную нагрузку при выполнении добровольцами-испытуемыми различных задач был проведен ряд экспериментов.

Эксперимент состоял в прохождении испытуемыми серий игр в VR-шлеме для проверки различных когнитивных функций, а также оценки функционального покоя.

Циклограмма исследования выглядела следующим образом:

1. функциональный покой;
2. игра 1. Координация;
3. покой 1;
4. игра 2. Концентрация;
5. покой 2;
6. игра 3. Реакция;
7. покой 3;
8. игра 4. Память;

9. покой 4;
10. игра 5. Синхронизация;
11. покой 5;
12. функциональный покой.

Функциональный покой и игры длились каждый по 3 минуты. Покой после игры длился 1 минуту. Функциональный покой и покой после игры проводились с открытыми глазами. Вариативность сценария объясняется необходимостью проверки воспроизводимости результатов исследования при разных когнитивных нагрузках, и попытками найти общие закономерности в ритмах головного мозга.

Каждый испытуемый размещался на стуле. На него крепились электрокардиографические электроды на запястья, на голову надевались VR-шлем с айттрекингом и ЭЭГ-шапочка. В руках испытуемый держал джойстики для управления в виртуальной реальности. ЭЭГ-шапочка регистрировала сигнал в стандартных отведениях по униполярной схеме 10–20: Fp1 и Fp2 (лобные), C3 и C4 (центральные), O1 и O2 (затылочные). Нечетные цифровые индексы соответствуют электродам над левым, а четные над правым полушарием мозга. В исследовании использовался электроэнцефалограф «Нейрон-Спектр 3».

В эксперименте были задействованы 11 человек. Всего было проведено 11 испытаний, каждый испытуемый проходил последовательно 5 игр на различные когнитивные нагрузки.

Испытание 1. «Сенсомоторная координация». В рамках этого испытания испытуемому предлагалось выполнить задачу по соотнесению шаров с определенными цветами, которые должны совпадать с цветом его перчаток в виртуальной реальности.

Результаты испытания оценивались по количеству ошибок, допущенных испытуемым. Чем меньше ошибок, тем лучше результат. Это испытание

помогает оценить способность испытуемого быстро и точно реагировать на визуальные стимулы, а также координировать свои движения в соответствии с полученной информацией.

Испытание 2. «Внимание». Задача испытуемого проследить за перемещением шаров, и выбрать тот, что в начале был окрашен в другой цвет. Это испытание направлено на проверку внимания и способности к концентрации.

Испытуемому показывали несколько шаров, которые могут быть одного цвета или разных цветов. Затем шары начинают перемещаться, и испытуемый должен внимательно следить за их перемещением. В процессе перемещения один из шаров меняет свой цвет, и испытуемому нужно запомнить, какой шар изначально был окрашен по-другому. Это испытание может быть использовано для оценки внимания и концентрации испытуемого, помогает понять насколько испытуемый может сосредоточиться на задаче и запомнить важные детали.

Испытание 3. «Скорость реакции». Задача испытуемого ловить летящие в него шары разных цветов, согласно цвету перчаток. Это испытание помогает оценить быстроту реакции и координацию движений испытуемого.

Испытание 4. «Память». Задача испытуемого запомнить в течение короткого времени порядок, в котором расположены фигуры на полках и разложить их в той же последовательности. Это испытание помогает оценить способность испытуемого к запоминанию и воспроизведению информации.

Испытание 5 «Реципрокная координация». Задача испытуемого повторить кривые, изображенные в пространстве. Это задание направлено на оценку способностей испытуемого координировать движения рук, а также контролировать и синхронизировать их.

Испытуемому могут быть предложены различные варианты кривых, которые он должен повторить, используя правую и левую руки. Это может

быть движение по траектории, похожей на восьмерку, зигзаг или спираль. Испытуемый должен максимально точно воспроизвести кривую, соблюдая заданную последовательность движений.

В общей сложности в экспериментах приняло участие 11 человек, в возрасте от 20 до 30 лет. Все участники были здоровы и не имели противопоказаний к исследованию. Получено и обработано 11 записей ЭЭГ.

1.8 Примеры обработки сигналов ЭЭГ на общедоступном наборе данных

В данном параграфе проведены 6 вариантов обработки общедоступных данных MOABB BCIC IV 2a [23] с помощью разных моделей глубокого обучения и классического машинного обучения: ShallowFBCSPNet, Deep4Net, EEGConformer, SVM, RandomForestClassifier и KNeighborsClassifier.

Модели были выбраны для анализа данных, поскольку они представляют собой различные подходы к обработке информации. Они позволяют выявить закономерности и особенности в данных.

1.8.1 ShallowFBCSPNet на общедоступном наборе данных

В качестве первого варианта обработки данных сигналов ЭЭГ выбрана модель ShallowFBCSPNet. ShallowFBCSPNet – это модель глубокого обучения для классификации сигналов мозга, используемая в задачах BCI (мозг-компьютерный интерфейс).

Архитектура модели состоит из нескольких основных компонентов:

1) входной слой: принимает на вход электрические сигналы мозга в виде временных рядов, представленных в виде матрицы размерности (количество каналов $\times$ количество временных точек);

2) слой фильтрации: применяет фильтры различных частот к выходным сигналам для извлечения признаков;

3) преобразование пространства признаков: используется для уменьшения размерности признаков и повышения их информативности;

4) сверточные слои: выполняют свертку признаков для извлечения более сложных шаблонов и закономерностей;

5) пулинг слои: уменьшают размерность признаков и повышают их инвариантность к малым сдвигам;

6) полносвязные слои: объединяют признаки из предыдущих слоев и выполняют классификацию сигналов.

Сначала производилась загрузка данных BCI Competition IV 2a [23] с помощью оболочки Braincode для загрузки через библиотеку MOABB.

Далее к набору данных были применены фильтрация, стандартизация и конвертация единиц измерения с помощью библиотеки braincode. Код включает следующие шаги предобработки данных:

- 1) выбор только данных ЭЭГ;
- 2) конвертация данных из Вольт в микровольты;
- 3) применение полосового фильтра с заданными частотами среза;
- 4) экспоненциальная стандартизация данных.

Затем данные подвергались этим преобразованиям с помощью функции `preprocess` с использованием указанных препроцессоров и параллельной обработке на всех доступных ядрах процессора.

После предварительной обработки данных были созданы окна данных на основе событий с помощью функции `create_windows_from_events` из библиотеки braincode.

Сначала были определены параметры для создания оконной функции, такие как смещение начала и конца проб в секундах, частота дискретизации

данных (sfreq) и предварительная загрузка данных. Код включает следующие шаги:

- 1) установка смещения начала пробы в секундах относительно событий;
- 2) извлечение частоты дискретизации данных (sfreq) из первого набора данных и проверка, что она одинакова для всех наборов данных в наборе данных;

- 3) расчёт смещения начала пробы в отсчетах (вычисляется количество отсчетов, соответствующих указанному временному смещению);

- 4) создание оконной функции, используя функцию `create_windows_from_events`, которая принимает датасет, смещение начала и конца проб в отсчетах, параметр `preload` для предварительной загрузки данных.

Далее набор данных был разделен на обучающий (`train_set`) и проверочный (`valid_set`) наборы.

После разделения набора данных была создана модель глубокого обучения. Здесь была использована библиотека PyTorch для создания и обучения нейронной сети на основе модели `ShallowFBCSPNet`.

Сначала была проверена доступность GPU и выбрано устройство GPU для обучения. Затем были определены: количество классов, количество каналов и временных отсчетов во входных данных. Создана модель `ShallowFBCSPNet` с указанными параметрами. Далее выведена информация о модели, и если доступен GPU, то модель отправляется на GPU для обучения.

Далее модель была обучена с помощью объекта `EEGClassifier`. `EEGClassifier` – объект `Braincode`, отвечающий за управление обучением нейронных сетей. Он наследует от `scorch NeuralNetClassifier`, поэтому логика обучения была такая же, как и в `Skorch`.

Сначала были установлены параметры для обучения, такие как learning rate (lr), весовое усиление (weight_decay), размер пакета (batch_size) и количество эпох (n_epochs).

Далее был создан экземпляр классификатора EEGClassifier, который принимает на вход модель, функцию потерь (NLLLoss), оптимизатор (AdamW), разделение данных на обучающую и тестовую выборки, параметры оптимизатора (lr и weight_decay), размер пакета, коллбэки (точность и планировщик скорости обучения), устройство для обучения (device), классы, на которых обучается модель, и количество эпох.

Модель была обучена на обучающей выборке с помощью метода fit(). После завершения обучения модель была оценена на тестовой выборке, и была вычислена точность предсказаний (test_acc). После получения и выведен результат тестирования модели в виде процента точности.

Результаты обучения модели на 30 эпохах показали, что точность на обучающей выборке постепенно увеличивается с 25% на первой эпохе до 97.22% на 22-й эпохе и далее остается примерно на одном уровне после 22-й эпохи.

Точность на тестовой выборке также увеличивается с 25,35% на первой эпохе до 53,47% на 22-й эпохе и далее остается примерно на этом уровне. При этом потери на тестовой выборке снижаются с 4,6092 до 1,1450 и также остаются примерно на одном уровне после 22-й эпохе.

Скорость обучения (learning rate) уменьшается с 0,0006 на первой эпохе до 0,0000 после 25-й эпохи. Среднее время обработки одной эпохи остается примерно одинаковым в диапазоне от 2,6 до 2,8 секунды.

В целом, модель достигла высокой точности на обучающей выборке.

1.8.2 Deep4Net на общедоступном наборе данных

В качестве второго варианта обработки данных ЭЭГ выбрана модель Deep4Net. Deep4Net – глубокая нейронная сеть, разработанная для обработки временных рядов, таких как сигналы ЭЭГ. Deep4Net состоит из нескольких блоков, включая сверточные слои, слои подвыборки (pooling), слои нормализации и полносвязные слои.

Основные характеристики архитектуры Deep4Net:

1) сверточные слои: используются для извлечения признаков из входных данных. Сверточные фильтры применяются к различным участкам входного сигнала для выявления характеристик;

2) слои подвыборки (pooling): позволяют уменьшить размерность данных, сохраняя наиболее важные признаки. Обычно используются после сверточных слоев;

3) слои нормализации: используются для стабилизации процесса обучения путем нормализации активаций нейронов;

4) полносвязные слои: последние слои, которые объединяют все признаки, извлеченные предыдущими слоями, для классификации или регрессии;

5) функция активации: обычно используются функции активации типа ReLU (Rectified Linear Unit) или сигмоиды для внесения нелинейности в модель;

6) Dropout: метод регуляризации, который случайным образом исключает некоторые нейроны во время обучения для предотвращения переобучения.

Загрузка набора данных, предварительная обработка данных, Создание оконной функции и разделение набора данных происходили так же, как и в п. 2.3.1 данной работы.

Модель нейронной сети определялась и настраивалась с использованием библиотеки PyTorch. Используемая модель – Deep4Net из библиотеки Braincode. Код проверяет, доступен ли графический процессор, и соответствующим образом настраивает устройство. Затем он устанавливает случайное начальное число для воспроизводимости, определяет количество выходных классов, извлекает количество каналов и временных шагов из набора данных и создает модель Deep4Net с конкретными конфигурациями. После, модель отображается с помощью torchinfo и отправляется в графический процессор GPU, если он доступен. После создания Deep4Net модель была обучена.

Был создан экземпляр класса EEGClassifier, который принимает на вход модель, функцию потерь (criterion), оптимизатор, набор данных для обучения (train_split), а также параметры для оптимизатора (lr и weight_decay). Далее были установлены размера батча (batch_size), количество эпох (n_epochs), а также список обратных вызовов (callbacks), которые будут использоваться во время обучения.

После, был вызван метод fit для обучения модели на наборе данных train_set. Параметр установлен в None, что означает, что метки (target) уже включены в набор данных. После обучения модели вызывается метод score для оценки точности модели на тестовом наборе данных test_set. Для этого используется атрибут target из метаданных набора данных. Результат оценки модели выводится в виде процента точности.

Результаты обучения модели на 110 эпох показали 57.99% на тестовом наборе данных. На эпохах 60–70 точность модели приближается к 100%. Это говорит о том, что обучение модели прошло успешно. За несколько эпох до конца обучения показатель loss резко возрастает. Это может быть связано с переобучением модели, она слишком хорошо подстраивается под обучающие данные и теряет способность корректно работать с новыми случаями.

Можно сделать вывод, что в результате обучения достигнута высокая точность предсказания: более 97–100% на обучающем наборе данных и более 52–59% на проверочном. Оценочная точность самой модели при этом составляет около 58%, что может свидетельствовать о ее хорошем качестве и эффективности проведенных экспериментов. Модель Deep4Net неплохо справилась с переобучением.

1.8.3 EEGConformer на общедоступном наборе данных

В качестве третьего варианта обработки была выбрана модель EEGConformer. EEGConformer – глубокая нейронная сеть, разработанная для обработки временных рядов, таких как сигналы ЭЭГ. EEGConformer базируется на концепции использования трансформеров (включая возможность моделирования долгосрочных зависимостей по времени).

Архитектура модели EEGConformer включает следующие основные компоненты:

- 1) входной слой: принимает на вход временной ряд данных ЭЭГ;
- 2) энкодер трансформера: состоит из нескольких слоев, которые выполняют механизм внимания и многомерную свертку для извлечения важных признаков из входных данных ЭЭГ;
- 3) дополнительные слои: могут включать в себя пулинг, нормализацию или другие операции для улучшения обучения и извлечения признаков;
- 4) выходной слой: генерирует прогнозы или классификацию на основе извлеченных признаков, например, в случае классификации различных типов ЭЭГ-сигналов.

Архитектура EEGConformer часто использует архитектурные элементы трансформеров, такие как механизм внимания и многомерные операции, чтобы эффективно анализировать временные зависимости в сигналах ЭЭГ.

Загрузка набора данных, предварительная обработка данных, Создание окон на основе событий и разделение набора данных происходили так же, как и в п. 2.3.1 данной работы.

Сначала была проверена доступность GPU, и в зависимости от результата установлена переменная `device`. Затем установлено начальное значение для генератора случайных чисел. После этого определены параметры модели: количество классов, количество каналов и длина временных шагов. Затем была создана модель EEGConformer с заданными параметрами. В конце выведена информация о модели и, если доступен GPU, модель отправляется на устройство.

Установлены значения параметров обучения: `learning rate (lr)`, `weight_decay`, размер батча (`batch_size`) и количество эпох (`n_epochs`). Далее был создан экземпляр класса EEGClassifier, который использует предобученную модель (`model`), функцию потерь NLLLoss, оптимизатор AdamW, предопределенное разделение данных на обучающую и тестовую выборки (`train_split`), а также заданные значения параметров обучения.

В список `callbacks` добавляется функция «ассигу» и экземпляр класса LRScheduler, который использует метод CosineAnnealingLR и максимальное количество эпох $T_{max}=n_epochs-1$. Модель обучена на обучающей выборке с использованием метода `fit`.

После обучения модель оценена на тестовой выборке с помощью метода `score`. Посчитана и выведена точность модели в процентах.

Обучение модели EEGConformer было проведено на 130 эпохах. При обучении модели удалось добиться 55.21% точности классификации на тестовом наборе данных.

Показатель `train` плавно растет, и к концу обучения составляет около 98%. Значения показателя `valid` начинают расти с отметки примерно в 25% и к 100 эпохе достигает 55% в среднем, после чего колеблется в районе этого

значения. Тенденция изменения значений показателей train, valid, loss и значение показателя epoch косвенно указывают на непрерывную работу модели.

Потери и скорость обучения убывают к концу процесса обучения: это означает, что модель постепенно адаптируется к обучающим данным. Однако небольшой рост отдельных значений потерь и небольшие колебания скорости обучения допустимы и даже желательны, поскольку помогают избежать локальных минимумов и функции потерь.

В целом предсказательная способность модели по итогам обучения получилась довольно неплохой для небольшого количества данных.

1.8.4 SVM на общедоступном наборе данных

В качестве четвертого варианта обработки была выбрана модель SVM. SVM – это классический метод машинного обучения, который используется для классификации и регрессии.

Архитектура SVM включает в себя следующие компоненты:

- 1) входной слой – этот слой принимает входные данные, которые могут быть представлены в виде вектора признаков;
- 2) Скрытый слой – этот слой состоит из нейронов, которые выполняют нелинейное преобразование входных данных;
- 3) выходной слой – этот слой выдает результат работы SVM. Для классификации этот класс, к которому принадлежит объект;
- 4) функция потерь – эта функция определяет, насколько хорошо SVM выполняет свою задачу. Для классификации обычно используется функция потерь, которая штрафует за неправильную классификацию;
- 5) Оптимизатор – этот компонент отвечает за обновление весов и смещений SVM, чтобы минимизировать функцию потерь;

6) Гиперпараметры – это параметры, которые не обучаются вместе с моделью, но влияют на ее работу. К ним относятся, например, размер ядра, коэффициент регуляризации и порог принятия решения;

7) Ядро – это функция, которая определяет, как входные данные преобразуются в скрытый слой. Ядро может быть линейным, полиномиальным, радиальным, базисным и т. д.

Загрузка набора данных, предварительная обработка данных, создание окон на основе событий и разделение набора данных происходили так же, как и в п. 2.3.1 данной работы.

Данные необходимо преобразовать для загрузки в модель. Создается список *i*, содержащий значения от 0 до `len(windows_dataset)-1`, далее передает этот список в метод `.get_sequence` объекта `windows_dataset`. Результат сохраняется в переменные *X* и *y* с помощью функции `shape`. Выводим размерность переменных *X* и *y* с помощью функции `shape`.

Далее производилось вычисление спектральных мощностей. На вход функции поступает два аргумента:

1) *signal* – входной сигнал, для которого нужно вычислить спектральные мощности;

2) *fs* – частота дискретизации сигнала, равная 250 Гц.

Алгоритм вычисления спектральных мощностей использует функцию `welc()`, которая выполняет быстрое преобразование Фурье (FFT) для сегментов сигнала и вычисляет спектральную плотность мощности (PSD).

Функция `welch()` возвращает два значения: массив частот и массив спектральных мощностей.

Функция `compute_spectral_power()` возвращает только массив спектральных мощностей.

После вычисления спектральных мощностей производилось извлечение временных признаков, а именно: среднее значение амплитуды по временным

точкам, стандартное отклонение амплитуды по временным точкам и медиана амплитуды по временным точкам. Также производилось вычисление частотных признаков, а именно спектральных мощностей.

Все извлеченные признаки были собраны в один массив `X_features`. Затем форма массива была изменена с помощью метода `.reshape()`, чтобы получить новый массив `X_feature_re` с заданными размерами. После этого код повторяет значения из массива `y` заданное количество раз, чтобы получить новый массив `y_features_re`. В результате получилось два массива: `X_features_re` и `y_features_re`. Необходимо проверить размерность полученных матриц признаков.

Данные необходимо преобразовать в двумерный формат (количество семплов и количество признаков). Два массива `X_resaped` и `X_features_re` объединяются в один массив `X_full`. Методом `np.concatenate()` массивы были соединены по указанной оси. После выполнения кода `X_full` содержит объединенные данные, а `y_resaped` сохранил свою форму.

На конечном этапе данные разделяются на обучающий и тестовый наборы и создается модель SVM с ядром RBF (Radial Basis Function). После чего модель обучается и выполняется предсказание на тестовом наборе данных.

Результаты работы модели SVM на общедоступном наборе данных представлены на Рисунке 3 – «Результаты работы модели SVM на общедоступном наборе данных».

	precision	recall	f1-score	support
feet	1.00	0.03	0.06	739
left_hand	0.25	1.00	0.40	730
right_hand	1.00	0.04	0.08	751
tongue	1.00	0.04	0.08	776
accuracy			0.27	2996
macro avg	0.81	0.28	0.15	2996
weighted avg	0.82	0.27	0.15	2996

Рисунок 3 – Результаты работы модели SVM на общедоступном наборе данных

Результаты показывают, что модель имеет низкую общую точность – 0,27, что означает, что она часто ошибается при классификации. Однако для некоторых классов модель показывает высокую точность, например, для *feet* (нога) – 1,0. Также результаты показывают, что модель лучше всего справляется с классификацией класса *feet* (нога), а хуже всего – с классификацией классов *left_hand* (левая рука) и *tongue* (язык).

1.8.5 RandomForestClassifier на общедоступном наборе данных

В качестве пятого варианта обработки была выбрана модель RandomForestClassifier. RandomForest (случайный лес) – это ансамблевый алгоритм машинного обучения, который представляет собой композицию из нескольких решающих деревьев.

Модель RandomForestClassifier состоит из следующих основных компонентов:

1) входные данные: модель принимает на вход набор данных, который содержит информацию о признаках и целевой переменной;

2) разделение данных: модель случайным образом разделяет данные на обучающую и тестовую выборки. Обучающая выборка используется для построения деревьев решений, а тестовая – для оценки качества модели;

3) построение деревьев решений: модель строит несколько деревьев решений на основе обучающей выборки. Каждое дерево решений имеет свои собственные параметры, такие как глубина, количество узлов и т. д.;

4) голосование: модель использует все деревья решений для определения класса объекта. Класс, за который проголосовало большинство деревьев, считается результатом классификации;

5) оценка качества: модель оценивает качество классификации на основе тестовой выборки;

6) выход: модель выводит предсказанный класс объекта.

Загрузка набора данных, предварительная обработка данных, создание окон на основе событий и разделение набора данных происходили так же, как и в п. 2.3.1 данной работы.

Преобразование данных для загрузки в модель происходило так же, как и в п. 2.3.4 данной работы.

Результаты работы модели RandomForestClassifier на общедоступном наборе данных представлены на Рисунке 4 – «Результаты работы модели RandomForestClassifier на общедоступном наборе данных».

	precision	recall	f1-score	support
feet	0.99	0.98	0.98	739
left_hand	0.98	0.99	0.99	730
right_hand	0.98	0.99	0.98	751
tongue	0.99	0.99	0.99	776
accuracy			0.98	2996
macro avg	0.99	0.98	0.98	2996
weighted avg	0.99	0.98	0.98	2996

Рисунок 4 – Результаты работы модели RandomForestClassifier на общедоступном наборе данных

Результаты показывают высокую точность и полноту модели для каждого из признаков. Общая точность модели составляет 0,98, что говорит о том, что модель правильно классифицирует примеры в 98% случаях. *F1-score* составляет 0,98 это означает, что модель хорошо справляется с классификацией всех признаков.

1.8.6 KNeighborsClassifier на общедоступном наборе данных

В качестве пятого варианта обработки была выбрана модель KNeighborsClassifier. KNeighborsClassifier – это модель машинного обучения, которая используется для классификации данных. Она основана на методе ближайших соседей (k-nearest neighbors, kNN). Модель KNeighborsClassifier использует расстояние между объектами для определения их принадлежности к классам.

Архитектура модели KNeighborsClassifier включает в себя следующие компоненты:

1) входные данные: модель принимает на вход набор объектов, каждый из которых представлен в виде вектора признаков;

2) метрика расстояния: модель использует определенную метрику расстояния для вычисления расстояния между объектами. Наиболее распространенными метриками являются евклидово расстояние и менхэттенское расстояние;

3) выбор k ближайших соседей: модель выбирает k ближайших соседей для каждого объекта. Значение k является гиперпараметром модели и может быть настроено в зависимости от задачи;

4) классификация: модель присваивает объекту класс, который является наиболее распространенным среди его k ближайших соседей;

5) выходные данные: модель выдает предсказание класса для каждого объекта во входном наборе данных.

Модель `KNeighborsClassifier` имеет некоторые недостатки. Она чувствительна к шуму и выбросам в данных, а также требует большого объема памяти для хранения всех объектов в наборе данных. Кроме того, модель не может эффективно обрабатывать большие объемы данных.

Загрузка набора данных, предварительная обработка данных, создание окон на основе событий и разделение набора данных происходили так же, как и в п. 2.3.1 данной работы.

Преобразование данных для загрузки в модель происходило так же, как и в п. 2.3.4 данной работы.

Результаты работы модели `KNeighborsClassifier` на общедоступном наборе данных представлены на Рисунке 5 – «Результаты работы модели `KNeighborsClassifier` на общедоступном наборе данных».

	precision	recall	f1-score	support
feet	0.32	0.29	0.30	739
left_hand	0.33	0.25	0.29	730
right_hand	0.29	0.20	0.24	751
tongue	0.31	0.50	0.38	776
accuracy			0.31	2996
macro avg	0.31	0.31	0.30	2996
weighted avg	0.31	0.31	0.30	2996

Рисунок 5 – Результаты работы модели KNeighborsClassifier на общедоступном наборе данных

В целом результаты модели показали точность 0,31 (accuracy), что означает, что в среднем модель правильно распознает 31% объектов. Наибольший recall 50% модель показала в распознавании tongue (языка), что говорит о том, что модель верно определяет данный класс в 50% случаев.

Наилучший показатель precision 0,33 модель показала при распознавании левой руки (left_hand), что означает верное определение левой руки в 33% случаев. F1-score показывает сбалансированный результат работы модели. Наилучший показатель f1-score 0,38 модель также показала в распознавании языка.

После обработки данных с помощью вышеописанных моделей были получены результаты, которые позволили оценить эффективность каждой из них. Результаты показали, что классические модели показали лучшие результаты по сравнению с нейронными сетями.

1.9 Примеры обработки сигналов ЭЭГ на собранном наборе данных

В этом параграфе проведены 6 вариантов обработки собранного набора данных, содержащего сигналы ЭЭГ с помощью разных моделей глубокого обучения и машинного обучения: ShallowFBCSPNet, Deep4Net, EEGConformer, SVM, RandomForestClassifier и KNeighborsClassifier.

1.9.1 ShallowFBCSPNet на собранном наборе данных

Архитектура модели ShallowFBCSPNet описана в п. 2.3.1 данной работы.

Создается набор данных путем обработки файлов в указанном каталоге. Сперва инициализируются два пустых списка: `eeg_array` и `target`. Перебираются все файлы в каталоге. Для записей с частотой 250 Гц считываются файлы `.edf` и `.csv`.

Далее происходит извлечение данных во время игр из этих файлов, и такие же по длительности данные во время отдыха, это необходимо, чтобы исключить дисбаланс. Извлеченные данные записываются в массив, а соответствующие им таргеты в другой массив.

Для записей с частотой 500 Гц процедура аналогична, но с понижением частоты до 250 Гц. На выходе получаем два массива: по 6 временных отрезков равных по длительности для каждого участника и соответствующие им таргеты во втором массиве.

Поскольку модель ShallowFBCSPNet относится к библиотеке `braincode` необходимо привести данные в нужный формат. Применяем полосовой фильтр 4–38 Гц и стандартизуем данные.

Далее была применена оконная функция. Из датасета берется первый набор данных (`dataset[0]`) и из него извлекается частота дискретизации. Затем

определяется длина окна в секундах и вычисляется количество выборок для этой длины окна, умножив частоту дискретизации на длину окна. Также вычисляется размер шага окна, который равен половине длины окна. После этого вызывается функция, которая создает окна фиксированной длины из набора данных.

После оконной функции набор данных был поделен на train и test в соотношении 80 на 20. Далее была создана модель ShallowFBCSPNet для 6 классов и обучена на 5 эпохах.

Обучение модели ShallowFBCSPNet на собственных данных было проведено на 3 эпохах. При обучении модели удалось добиться 25,00% точности классификации на тестовом наборе данных. Результат показывает, что модель имеет низкую точность.

1.9.2 Deep4Net на собранном наборе данных

Архитектура модели Deep4Net описана в п. 2.3.2 данной работы. Предобработка данных описана в п. 2.4.1 данной работы. Создание модели описано в п. 2.3.2 данной работы.

Обучение модели Deep4Net на собственных данных было проведено на 4 эпохах. При обучении модели удалось добиться 21,43% точности классификации на тестовом наборе данных. Это означает, что модель корректно классифицировала 21,43% объектов из тестовой выборки.

Результат показывает, что модель Deep4Net имеет низкую точность. Это может быть связано с несколькими факторами:

- недостаточное количество данных. Для обучения модели может быть недостаточно данных, на которых она обучалась;
- сложность задачи. Задача классификации может быть сложной и требовать более сложной модели.

1.9.3 EEGConformer на собранном наборе данных

Архитектура модели EEGConformer описана в п. 2.3.3 данной работы. Предобработка данных описана в п. 2.4.1 данной работы. Создание модели описано в п. 2.3.3 данной работы.

Обучение модели EEGConformer на собственных данных было проведено на 4 эпохах. При обучении модели удалось добиться 30,12% точности классификации на тестовом наборе данных. Результат показывает, что модель имеет низкую точность. Это означает, что модель верно классифицировала 30,12% объектов тестовой выборки.

Результат показывает, что модель имеет низкую точность. Это может быть связано с несколькими факторами:

- недостаточное количество данных. Модель обучалась на небольшом объеме данных, что не позволило ей выявить все закономерности и особенности;
- сложность задачи. Классификация объектов может быть сложной задачей, особенно если данные содержат множество признаков и параметров;
- неподходящая архитектура модели. Архитектура модели EEGConformer может не подходить для решения данной задачи;

Для улучшения точностей моделей глубокого обучения можно предпринять следующие шаги:

- увеличить объем данных. Собрать больше данных для обучения модели;
- изменить методы предварительной обработки данных. Использовать методы, такие как стандартизация или нормализация, для улучшения качества данных;

– использовать более простые алгоритмы обучения для собранного набора данных.

1.9.4 SVM на собранном наборе данных

Архитектура модели SVM описана в п. 2.3.4 данной работы. Предобработка данных описана в п. 2.4.1 данной работы. Создание модели описано в п. 2.3.4 данной работы.

Результаты обучения модели SVM на собственном наборе данных представлено на рисунке 6 – «Результаты работы модели SVM на собственном наборе данных».

	precision	recall	f1-score	support
координация	0.88	0.88	0.88	56
концентрация	0.93	0.93	0.93	61
реакция	1.00	0.93	0.96	71
память	0.96	0.93	0.95	56
синхронизация	0.96	0.92	0.94	51
покой	0.85	0.97	0.91	65
accuracy			0.93	360
macro avg	0.93	0.93	0.93	360
weighted avg	0.93	0.93	0.93	360

Рисунок 6 – Результаты работы модели SVM на собственном наборе данных

Результаты показывают, что модель SVM (метод опорных векторов) хорошо справляется с задачей классификации. Это подтверждается значениями метрик точности, полноты и F1-меры, которые близки к 1.

Общая точность модели (accuracy) равно 0,93 или 93%. Это означает, что модель правильно классифицирует 93% объектов.

Лучше всего модель SVM справляется с классом «реакция» - точность этого класса равна 100%. Это говорит о том, что все объекты, классифицированные как «реакция», действительно относятся к этому классу.

Хуже всего модель справляется с классом «покой» - точность этого класса составляет 85%. Это означает, что 15% объектов, классифицированных как «покой», на самом деле относятся к другим классам.

Такие результаты говорят о том, что модель SVM является эффективным инструментом для классификации объектов. Однако, несмотря на высокую общую точность, модель может допускать ошибки при классификации некоторых объектов. Это может быть связано с особенностями данных или с тем, что некоторые классы являются более сложными для классификации.

1.9.5 RandomForestClassifier на собранном наборе данных

Архитектура модели RandomForestClassifier описана в п. 2.3.5 данной работы. Предобработка данных описана в п. 2.4.1 данной работы. Создание модели описано в п. 2.3.5 данной работы.

Результаты обучения модели RandomForestClassifier на собственном наборе данных представлено на рисунке 7 – «Результаты работы модели RandomForestClassifier на собственном наборе данных».

	precision	recall	f1-score	support
координация	0.83	0.86	0.84	56
концентрация	0.84	0.89	0.86	61
реакция	0.98	0.87	0.93	71
память	0.98	0.89	0.93	56
синхронизация	0.88	0.90	0.89	51
покой	0.82	0.91	0.86	65
accuracy			0.89	360
macro avg	0.89	0.89	0.89	360
weighted avg	0.89	0.89	0.89	360

Рисунок 7 – Результаты работы модели RandomForestClassifier на собственном наборе данных

Результаты показывают, что модель RandomForestClassifier хорошо справляется с задачей классификации, так как значения метрик точности, полноты и F1-меры близки к 1. Общая точность (accuracy) модели RandomForestClassifier равна 89%. Это означает, что модель правильно классифицирует 89% объектов. Лучше всего модель справляется с классами «реакция» и «память» точность составляет 98%. Хуже всего модель справляется с классификацией класса «покой» точность этого класса составляет 82%.

В целом результаты показывают, что модель имеет высокую точность и полноту для всех шести классов. Точность и полнота для каждого класса близки к 0,9 и выше, что говорит о том, что модель хорошо справляется с предсказанием результатов.

1.9.6 KneighborsClassifier на собранном наборе данных

Архитектура модели KneighborsClassifier описана в п. 2.3.6 данной работы. Предобработка данных описана в п. 2.4.1 данной работы. Создание модели описано в п. 2.3.6 данной работы.

Результаты обучения модели KneighborsClassifier на собственном наборе данных представлены на рисунке 8 – «Результаты работы модели KneighborsClassifier на собственном наборе данных».

	precision	recall	f1-score	support
координация	0.90	0.84	0.87	56
концентрация	0.76	0.82	0.79	61
реакция	0.98	0.89	0.93	71
память	0.94	0.82	0.88	56
синхронизация	0.93	0.82	0.87	51
покой	0.73	0.94	0.82	65
accuracy			0.86	360
macro avg	0.87	0.85	0.86	360
weighted avg	0.87	0.86	0.86	360

Рисунок 8 – Результаты работы модели KNeighborsClassifier на собственном наборе данных

Результаты показали, что модель KNeighborsClassifier хорошо справляется с задачей классификации для большинства параметров. Общая точность (accuracy) для модели KNeighborsClassifier равна 86%. Это означает, что модель правильно классифицирует 86% объектов. Однако для некоторых классов, таких как «покой» и «концентрация» точность модели значительно ниже и составляет 73%. Это может указывать на то, что модель плохо справляется с распознаванием данных признаков. Лучше всего модель справляется с классом «реакция», точность составляет 98%.

В целом результаты показывают, что модель имеет высокую точность и полноту для некоторых классов.

3. Обсуждение результатов

2.1 Модели глубокого обучения

Методы глубокого машинного обучения (DL) являются новыми подходами, используемыми для анализа сигналов ЭЭГ. Они позволяют выявлять закономерности и паттерны в данных, которые могут быть полезны для диагностики и реабилитации различных когнитивных заболеваний.

С помощью методов глубокого обучения можно анализировать большие объемы данных ЭЭГ, что позволяет получить более точные результаты. Это особенно важно при исследовании сложных процессов, происходящих в мозге человека.

В работе были рассмотрены 2 набора данных: общедоступный набор данных MOABB BCIC IV 2a [24] и собранный датасет.

В качестве моделей машинного обучения были рассмотрены модели: ShallowFBCSPNet, Deep4Net и EEGConformer с платформы braincode. Модели были применены к каждому набору данных для того, чтобы сравнить их эффективность и точность для отслеживания психофункционального состояния человека по данным мозговых волн ЭЭГ. Для реализации алгоритмов использовался язык программирования Python.

Точность этих моделей были исследованы путем сохранения 80% данных в тренировочном наборе и 20% в тестовом наборе данных. В таблице 3 – «Точность моделей глубокого на общедоступных данных» представлена производительность моделей глубокого обучения в процентах (%) на общедоступном наборе данных, полученная при реализации моделей с сохранением 80% данных в тренировочном наборе данных и 20% в тестовом наборе данных.

Таблица 3 – Точность моделей глубокого обучения на общедоступном наборе данных

Модель	Тестовый набор данных
ShallowFBCSPNet	53,47%
Deep4Net	57,99%
EEGConformer	55,21%

Из таблицы 3 – «Точность моделей глубокого обучения на общедоступном наборе данных» можно заметить, что показатели классификации архитектуры ShallowFBCSPNet составляют 53,47% на тестовом наборе данных и 93% на тренировочном наборе данных. Архитектура Deep4Net составляет 57,99% на тестовом наборе и 99% на тренировочном наборе данных. Архитектура EEGConformer составляет 55,21% на тестовом наборе данных и 98% на тренировочном наборе данных.

Из результатов можно заметить, что распознавание набора данных составляет 57,99% для архитектуры Deep4Net, в то время как другие архитектуры глубокого обучения показали результаты чуть хуже.

В таблице 4 – «Точность моделей глубокого обучения на собственном наборе данных» представлены результаты производительности моделей глубокого обучения в процентах (%) на собственном наборе данных, полученная при реализации моделей с сохранением 80% данных в тренировочном наборе данных и 20% в тестовом наборе данных.

Таблица 4 – Точность моделей глубокого обучения на собранном наборе данных

Модель	Тестовый набор данных
ShallowFBCSPNet	25%
Deep4Net	21,43%
EEGConformer	30,12%

Из таблицы 4 – «Точность моделей глубокого обучения на собранном наборе данных можно заметить, что показатели работы модели ShallowFBCSPNet составляют 25% на тестовом наборе данных. Что в 2 раза хуже результатов, полученных на общедоступных данных. Производительность архитектуры Deep4Net составляет 21,43% на тестовом наборе данных. Что почти в 3 раза хуже результатов, полученных на общедоступном наборе данных. Из результатов можно заметить, что производительность архитектуры EEGConformer на тестовом наборе данных составляет 30,12%, в то время как другие архитектуры показали результат как минимум на 5% хуже на тестовом наборе данных.

Результаты полученные при реализации моделей глубокого обучения: ShallowFBCSPNet, Deep4Net и EEGConformer на общедоступном наборе данных, носят умеренный характер, как на этапе обучения, так и на этапе тестирования. В среднем от данных моделей на общедоступном наборе данных можно добиться 55,5% точности производительности.

В свою очередь, результаты полученные при реализации этих же моделей глубокого обучения на собранном наборе данных показали результаты намного хуже. В среднем от данных моделей на собранном наборе данных можно добиться 25,5% точности производительности, что почти в 2 раза меньше показателей достигнутых на общедоступном наборе данных.

Полученная разница в результатах объясняется следующими факторами:

- качество данных. Собранный набор данных может содержать больше ошибок и несоответствий, что снижает точность модели;
- объем данных. Общедоступный набор данных в 2 раза больше собранного набора данных, что позволяет модели лучше изучить закономерности и повысить точность.

В дальнейшем для улучшения результатов на собранном наборе данных можно предпринять следующие шаги:

- улучшить качество записи данных. Убрать ошибки и несоответствия правилам записи ЭЭГ;
- увеличить объем данных. Собрать больше данных или использовать методы увеличения объема данных, такие как аугментация.

2.2 Классические модели машинного обучения

Традиционные методы машинного обучения (ML) являются основными подходами, используемыми для анализа сигналов ЭЭГ. Эти методы включают в себя извлечение временных, частотных и нелинейных характеристик предварительно обработанных сигналов ЭЭГ. Подходы классических методов машинного обучения включали три ключевых этапа: предварительная обработка, извлечение признаков и классификация. Предварительная обработка включала в себя удаление шума и артефактов из сигнала ЭЭГ. Извлечение признаков подразумевало выделение из сигнала ЭЭГ характеристик, которые могут быть использованы для классификации и прогнозирования. Классификация же позволила определить, к какому классу или категории принадлежал сигнал ЭЭГ на основе выделенных признаков.

Так же, как и в п.3.1 в работе были рассмотрены 2 набора данных: тот же общедоступный набор данных MOABB BCIC IV 2a [24] и собранный набор данных.

В качестве классических моделей машинного обучения были рассмотрены модели: SVM, RandomForestClassifier и KNeighborsClassifier. Модели были применены к каждому набору данных для того, чтобы сравнить их эффективность и точность для отслеживания психофункционального состояния человека по данным мозговых волн ЭЭГ. Для реализации алгоритмов использовался язык программирования Python.

Производительность и пригодность этих моделей были исследованы путем сохранения 80% данных в тренировочном наборе и 20% в тестовом наборе данных. В таблице 5 – «Эффективность классических моделей машинного обучения на общедоступных данных» представлена производительность классических моделей машинного обучения в процентах (%) на общедоступном наборе данных, полученная при реализации моделей с сохранением 80% данных в тренировочном наборе данных и 20% в тестовом наборе данных. В качестве метрики для сравнения выбрана F1-score.

Таблица 5 – Эффективность классических моделей МО на общедоступных данных

	SVM	RandomForestClassifier	KNeighborsClassifier
Feet	6 %	98 %	30 %
Left hand	40 %	99 %	29 %
Right hand	8 %	98 %	24 %
Tongue	8 %	99 %	38 %
accuracy	27%	98%	31 %

Из Таблицы 5 – «Эффективность классических моделей МО на общедоступных данных» можно заметить, что показатели метрики F1-score для архитектуры SVM составляют 6%, 40%, 8% и 8% соответственно для

классов «feet», «left hand», «right hand» и «tongue». В целом модель SVM имеет точность 27% на общедоступном наборе данных. Показатели метрики F1-score для архитектуры KNeighborsClassifier составляют 30%, 29%, 24% и 38% для классов «feet», «left hand», «right hand» и «tongue» соответственно. В целом модель KNeighborsClassifier имеет точность 31% на общедоступном наборе данных. Из результатов можно заметить, что показатели метрики F1-score для архитектуры RandomForestClassifier имеют наилучшие результаты и составляют 98%, 99%, 98% и 99% соответственно для классов «feet», «left hand», «right hand» и «tongue». В целом модель RandomForestClassifier имеет точность 98% на общедоступном наборе данных.

Также из результатов классификации можно сделать вывод, что на общедоступном наборе данных хуже всего модели справлялись с классами правая рука «Right hand» и ноги «Feet». Данных классов было меньше представлено в открытом наборе данных, что затруднило обучение моделей.

В таблице 6 – «Эффективность классических моделей МО на собранном наборе данных» представлены результаты производительности моделей классического машинного обучения в процентах (%) на собственном наборе данных, полученная при реализации моделей с сохранением 80% данных в тренировочном наборе данных и 20% в тестовом наборе данных. В качестве метрики для сравнения выбрана F1-score.

Таблица 6 – Эффективность классических моделей МО на собранном наборе данных

	SVM	RandomForestClassifier	KNeighborsClassifier
Координация	88 %	84 %	87 %
Концентрация	93 %	86 %	79 %
Реакция	96 %	93 %	93 %
Память	95 %	93 %	88 %
Синхронизация	94 %	89 %	87 %
Покой	91 %	86 %	82 %
ассурасу	93 %	89 %	86 %

Из таблицы 6 – «Эффективность классических моделей МО на собранном наборе данных» можно заметить, что показатели метрики F1-score для архитектуры SVM составляют 88%, 93%, 96%, 95%, 94% и 91% соответственно для классов «координация», «концентрация», «реакция», «память», «синхронизация» и «покой». В целом модель SVM имеет точность 93% на собранном наборе данных. Показатели метрики F1-score для архитектуры RandomForestClassifier составляют 84%, 86%, 93%, 93%, 89% и 86% для классов «координация», «концентрация», «реакция», «память», «синхронизация» и «покой» соответственно. В целом модель RandomForestClassifier имеет точность 89% на собранном наборе данных. Показатели метрики F1-score для архитектуры KNeighborsClassifier составляют 87%, 79%, 93%, 88%, 87% и 82% для классов «координация», «концентрация», «реакция», «память», «синхронизация» и «покой» соответственно. В целом модель KNeighborsClassifier имеет точность 86%.

На собранном наборе данных лучше всего проявила себя архитектура *SVM*, модель классифицирует классы с точностью 93%, что лучше результатов, которые показали другие классические модели.

Также из результатов классификации можно сделать вывод, что на собранном наборе данных хуже всего модели справлялись с классами: «Покой», «Концентрация» и «Координация». Это может быть связано с тем, что сигналы с испытуемых снимались в вечернее время, когда концентрация заметно ухудшается.

Анализ сравнения результатов работы модели на общедоступном наборе данных и на собранном наборе данных показал, что модель *SVM* в 3,5 раза точнее работает с собранным набором данных. В свою очередь архитектура *RandomForestClassifier* проявила себя хорошо в обоих случаях, как на общедоступном наборе данных, так и на собранном наборе данных. Модель *KNeighborsClassifier* так же в 2 раза точнее работает с собранным набором данных. Из этих наблюдений можно сделать вывод, что модель *SVM* лучше работает на небольшом количестве данных. Модель *RandomForestClassifier* работает хорошо как на большом количестве данных, так и на небольшом количестве данных. В свою очередь архитектура *KNeighborsClassifier* так же лучше работает с небольшим количеством данных.

ЗАКЛЮЧЕНИЕ

В данной выпускной квалификационной работе была поставлена основная цель – провести исследование оценки когнитивных функций на основе анализа биосигналов ЭЭГ с применением машинного обучения. Для достижения этой цели были поставлены определенные задачи.

Вначале был проведен анализ литературы, который включал в себя существующие системы реабилитации и методы машинного обучения, применяемых для задач классификации сигналов ЭЭГ. В существующие методы обработки сигналов электроэнцефалографии с помощью методов машинного обучения входили архитектуры: MLP, CNN, RNN и SVM. В задаче определения депрессии на основе сигналов мозговых волн лучшую точность выдали модель глубокого обучения RNN (97,95%, 96,40% и 93,90 на проценте данных в тестовом наборе 20%, 30%, 40% соответственно) и классический метод машинного обучения SVM (97,65%, 97,18%, 95,89% на проценте данных в тестовом наборе 20%, 30%, 40% соответственно). Это позволило определить подходящие алгоритмы, которые были использованы в разработанной системе.

Затем была выполнена задача анализа известных общедоступных наборов данных и создание собственного набора данных. В качестве общедоступного набора данных для сравнения с собранным набором данных, был выбран MOABV BCIC IV 2a. В наборе данных MOABV были собраны сигналы ЭЭГ с испытуемых, которым предлагалось вообразить движение: правой рукой, левой рукой, ступнями и языком.

Также были определены методы снятия сигналов ЭЭГ и когнитивные нагрузки. В испытании участвовали 11 относительно здоровых добровольцев, которым предлагалось пройти 5 игр-тестов на различные когнитивные нагрузки.

Данные сигналов ЭЭГ были собраны и предварительно обработаны. Для этого использовался электроэнцефалограф, позволяющий регистрировать электрическую активность мозга. Собранные данные были очищены от шумов и артефактов, а также преобразованы в нужный формат для обработки данных моделями глубокого машинного обучения и классическими моделями машинного обучения.

Были выбраны и применены различные алгоритмы машинного обучения для задачи классификации когнитивных нагрузок по сигналам ЭЭГ. Архитектуры моделей включали в себя 3 модели глубокого обучения EEGConformer, Deep4Net и ShallowFBCSPNet и 3 модели классического машинного обучения SVM, RandomForestClassifier, KNeighborsClassifier.

В завершении работы был проведен анализ работы 6 моделей (3 из которых – модели глубокого обучения и 3 – классические методы машинного обучения) на общедоступном наборе данных и на собранном наборе данных. Анализ позволяет понять в каких случаях использовать ту или иную модель машинного обучения.

Результат работы показал, что поставленная гипотеза, говорящая о том, что по сигналам ЭЭГ можно различать когнитивную нагрузку оказалась верной. Модели классического машинного обучения классифицировали когнитивные нагрузки по данным мозговых волн с точностью 93% (SVM), 89% (RandomForestClassifier) и 86% (KNeighborsClassifier).

Таким образом, в результате выпускной квалификационной работы были исследованы сигналы ЭЭГ для разработки системы реабилитации с использованием методов машинного обучения. Система действительно способна классифицировать когнитивные нагрузки по электрическим сигналам мозговой активности и помогать нейроспециалистам по результатам как дальше выстраивать план реабилитации для пациентов, имеющих когнитивные нарушения.

Дальнейшие исследования в этой области могут включать расширение набора данных для более точной классификации когнитивных нагрузок, разработку новых алгоритмов машинного обучения для повышения точности классификации и изучения влияния различных факторов на результаты классификации.

СПИСОК ИСПОЛЬЗОВАННЫХ ИСТОЧНИКОВ

1. К 2030 году самой распространенной причиной для больничного может стать депрессия. – URL: <https://www.kommersant.ru/doc/5582387> (дата обращения: 23.02.2024). – Текст: электронный.
2. Kuznetsov, A. A. Cognitive Rehabilitation in Virtual Reality (Modern Review) / A. A. Kuznetsov, V. I. Borisov. – Текст: электронный // 2023 IEEE Ural-Siberian Conference on Computational Technologies in Cognitive Science, Genomics and Biomedicine (CSGB) 2023 IEEE Ural-Siberian Conference on Computational Technologies in Cognitive Science, Genomics and Biomedicine (CSGB). – 2023. – С. 94-99.
3. Биомедицинские сигналы и изображения в цифровом здравоохранении: хранение, обработка и анализ : учебное пособие / В.С. Кубланов, А.Ю. Долганов, В.Б. Костоусов [и др.] ; [под общ. ред. В. С. Кубланова] ; Мин-во науки и высш. образования РФ. — Екатеринбург: Изд-во Урал. ун-та, 2020.— 240 с.
4. Virtual Reality for Neurorehabilitation and Cognitive Enhancement / D. D. Georgiev, I. Georgieva, Z. Gong [и др.]. – Текст: электронный // Brain Sciences. – 2021. – Т. 11. – № 2. – С. 221. – URL: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC7918687/> (дата обращения: 03.03.2024).
5. Virtual Reality for the Rehabilitation of Acquired Cognitive Disorders: A Narrative Review / V. Catania, F. Rundo, S. Panerai, R. Ferri. – Текст: электронный // Bioengineering. – 2024. – Vol. 11. – Virtual Reality for the Rehabilitation of Acquired Cognitive Disorders. – № 1. – P. 35. – URL: <https://www.mdpi.com/2306-5354/11/1/35> (дата обращения: 03.03.2024).
6. Virtual Reality for the Rehabilitation of Acquired Cognitive Disorders: A Narrative Review / V. Catania, F. Rundo, S. Panerai, R. Ferri. – Текст: электронный

// Bioengineering. – 2024. – Vol. 11. – Virtual Reality for the Rehabilitation of Acquired Cognitive Disorders. – № 1. – P. 35. – URL: <https://www.mdpi.com/2306-5354/11/1/35> (дата обращения: 03.03.2024).

7. Emotion recognition in EEG signals using deep learning methods: A review / M. Jafari, A. Shoeibi, M. Khodatars [и др.]. – Текст : электронный // Computers in Biology and Medicine. – 2023. – Т. 165. – Emotion recognition in EEG signals using deep learning methods. – С. 107450. – URL: <https://www.sciencedirect.com/science/article/pii/S0010482523009150> (дата обращения: 11.03.2024).

8. J.J. Bird, A. Ekart, C. D. Buckingham, and D. R. Faria, “Mental emotional sentiment classification with an eeg-based brain-machine interface”, in Proceedings of the International Conference on Digital Image and Signal Processing (DISP’19), Springer, 2019.

9. Sarkar, A. A deep learning-based comparative study to track mental depression from EEG data / A. Sarkar, A. Singh, R. Chakraborty. – Текст : электронный // Neuroscience Informatics. – 2022. – Т. 2. – № 4. – С. 100039. – URL: <https://www.sciencedirect.com/science/article/pii/S2772528622000012> (дата обращения: 11.03.2024).

10. Abinaya, S. Chapter 12 - Enhancing crop productivity through autoencoder-based disease detection and context-aware remedy recommendation system / S. Abinaya, M. K. K. Devi. – Текст : электронный // Application of Machine Learning in Agriculture / ред. М. А. Khan [и др.]. – Academic Press, 2022. – С. 239-262. – URL: <https://www.sciencedirect.com/science/article/pii/B978032390550300014X> (дата обращения: 16.03.2024).

11. Convolutional neural networks: an overview and application in radiology / R. Yamashita, M. Nishio, R. K. G. Do, K. Togashi. – Text : electronic // Insights into Imaging. – 2018. – Vol. 9. – Convolutional neural networks. – № 4. – P. 611-

629. – URL: <https://insightsimaging.springeropen.com/articles/10.1007/s13244-018-0639-9> (дата обращения: 16.03.2024).

12. RNN-based pavement moduli prediction for flexible pavement design enhancement / A. H. Al-Qaili, A. I. Al-Mansour, H. Al-Soliman, K. AlSharabi. – Текст : электронный // Case Studies in Construction Materials. – 2024. – Т. 20. – С. e02811. – URL: <https://www.sciencedirect.com/science/article/pii/S2214509523009920> (дата обращения: 11.03.2024).

13. All You Need to Know About Support Vector Machines. – URL: <https://www.spiceworks.com/tech/big-data/articles/what-is-support-vector-machine/> (date accessed: 10.03.2024). – Text : electronic.

14. Phillips, C. G. Localization of function in the cerebral cortex. Past, present and future / C. G. Phillips, S. Zeki, H. B. Barlow // Brain: A Journal of Neurology. – 1984. – Т. 107 (Pt 1). – С. 327-361.

15. Grealy, M. A. Improving cognitive function after brain injury: the use of exercise and virtual reality / M. A. Grealy, D. A. Johnson, S. K. Rushton // Archives of Physical Medicine and Rehabilitation. – 1999. – Т. 80. – Improving cognitive function after brain injury. – № 6. – С. 661-667.

16. Wiederhold, B. K. Virtual reality with fMRI: a breakthrough cognitive treatment tool / B. K. Wiederhold, M. D. Wiederhold. – Text : electronic // Virtual Reality. – 2008. – Vol. 12. – Virtual reality with fMRI. – № 4. – P. 259-267. – URL: <https://doi.org/10.1007/s10055-008-0100-3> (дата обращения: 16.03.2024).

17. First-person view of one's body in immersive virtual reality: Influence on episodic memory / L. Bréchet, R. Mange, B. Herbelin [и др.] // PloS One. – 2019. – Т. 14. – First-person view of one's body in immersive virtual reality. – № 3. – С. e0197763.

18. Нейрон-Спектр-3–19-канальный электроэнцефалограф для рутинных ЭЭГ-исследований. – URL:

<https://neurosoft.com/ru/catalog/eeg/neuron-spectrum-3> (дата обращения: 22.03.2024). – Текст: электронный.

19. Oostenveld, Robert; Praamstra, Peter (2001). “The five percent electrode system for high-resolution EEG and ERP measurements”. *Clinical Neurophysiology*. 112: 713–719 (дата обращения: 25.04.2024).

20. Ali Shueb. Application of Machine Learning to Epileptic Seizure Onset Detection and Treatment. PhD Thesis, Massachusetts Institute of Technology, September 2009 (дата обращения: 25.04.2024).

21. Zyma I, Tukaev S, Seleznev I, Kiyono K, Popov A, Chernykh M, Shpenkov O. Electroencephalograms during Mental Arithmetic Task Performance. *Data*. 2019; 4(1):14. <https://doi.org/10.3390/data4010014> (дата обращения: 25.04.2024).

22. ZuCo 2.0: A Dataset of Physiological Recordings During Natural Reading and Annotation / N. Hollenstein, M. Troendle, C. Zhang, N. Langer. – Текст: электронный // Proceedings of the Twelfth Language Resources and Evaluation Conference LREC 2020 / ред. N. Calzolari [и др.]. – Marseille, France: European Language Resources Association, 2020. – ZuCo 2.0. – С. 138-146. – URL: <https://aclanthology.org/2020.lrec-1.18> (дата обращения: 15.05.2024).

23. B Kemp, AH Zwinderman, B Tuk, HAC Kamphuisen, JJJ Oberyé. Analysis of a sleep-dependent neuronal feedback loop: the slow-wave microcontinuity of the EEG. *IEEE-BME* 47(9):1185-1194 (2000).

24. B Kemp, AH Zwinderman, B Tuk, HAC Kamphuisen, JJJ Oberyé. Analysis of a sleep-dependent neuronal feedback loop: the slow-wave microcontinuity of the EEG. *IEEE-BME* 47(9):1185-1194 (2000).

25. BCI Competition IV. – URL: <https://www.bbc.de/competition/iv/> (дата обращения: 01.05.2024). – Текст : электронный.

26. Divakarla, U. A Novel Approach towards Windows Malware Detection System Using Deep Neural Networks / U. Divakarla, K.H.K. Reddy, K.

Chandrasekaran – Текст : непосредственный. // Procedia Computer Science. 2022. Vol. 215. – P. 148-157.

27. Y. Freund and R. E. Schapire, “A decision-theoretic generalization of on-line learning and an application to boosting, “Journal of computer and System Sciences, vol. 55, no. 1, part 2, pp. 119-139, 1997.

28. Girshick, R. Fast R-CNN / R. Girshick arXiv:1504.08083 [cs]. – arXiv, 2015. – URL: <http://arxiv.org/abs/1504.08083> (дата обращения: 04.03.2024). – Текст : электронный.

29. Ткаченко О.Н., Дорохов В.Б., Свешников Д.С. Физиологические корреляты дремотного состояния при выполнении монотонной операторской деятельности // Вестник Московского государственного гуманитарного университета им. М.А. Шолохова. Педагогика и психология. 2015. №2. С. 84 – 92.

30. Психогенетика: учебник / И. В. Равич-Щербо, Т. М. Марютина, Е. Л. Григоренко / под ред. И. В. Равич-Щербо. М.: Аспект Пресс, 2002. 447 с.

31. Tietze H. Wurzburg I. Stages of fatigue during long-duration driving reflected in alpha-related events in the EEG // International Conference on Traffic and Transport Psychology. Bern, 2000

32. Ma, C. Hierarchical Convolutional Features for Visual Tracking // 2015 IEEE International Conference on Computer Vision (ICCV) 2015 IEEE International Conference on Computer Vision (ICCV). – Santiago, Chile: IEEE, 2015. – P. 3074-3082.

33. Wang, X. Non-local Neural Networks // 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). – Salt Lake City, UT, USA: IEEE, 2018. – P. 7794-7803.

34. С.и, О. Ритмы ЭЭГ и когнитивные процессы / О. С.и. – Текст : электронный // Современная зарубежная психология. – 2018. – Т. 4. – № 1. –

С. 91-108. – URL: https://psyjournals.ru/journals/jmfp/archive/2015_n1/76178 (дата обращения: 26.02.2024).

35. Применение машинного обучения при анализе ЭЭГ для выявления фобической реакции в виртуальной реальности / А. Д. Обухов, И. Л. Коробова, А. О. Назарова, Д. В. Зайцева. – Текст : электронный // Информационно-управляющие системы. – 2023. – № 4. – С. 56-70. – URL: <http://ius.ru/index.php/ius/article/view/15961> (дата обращения: 6.05.2024).

36. Соболев, М. Е. Применение математических методов количественного анализа электроэнцефалограмм для дифференциации нервно-психических расстройств: научный доклад: направление подготовки 03.06.01 «Физика и астрономия»; направленность 03.06.01_12 «Биофизика» / М. Е. Соболев. – Текст : электронный. – 2023. – Применение математических методов количественного анализа электроэнцефалограмм для дифференциации нервно-психических расстройств. – URL: <https://elib.spbstu.ru/en/doc/info?key=ru%5Cspstu%5Cvkr%5C26312> (дата обращения: 8.05.2024).

37. J.-R. Huang, et al. Application of multivariate empirical mode decomposition and sample entropy in EEG signals via artificial neural networks for interpreting depth of anesthesia // Entropy. 2013. Vol. 15(9). P. 3325 – 3339.

38. Mathew B. A. Entropy of electroencephalogram (EEG) signals changes with sleep state / master's theses. University of Kentucky, 2003 P. 203

39. Fenwick, T. Exploring the impact of digital technologies on professional responsibilities and education / T. Fenwick, R. Edwards. – Text: electronic // European Education Research Journal. – 2016. – Vol. 15. - №1. – P. 117-131. – URL:<https://doi.org/10.1177/1474904115608387> (дата обращения 7.05.2024).

40. Lee, L. N. Potential of Augmented Reality and Virtual Reality Technologies to Promote wellbeing in Older Adults / L. N. Lee, M. J. Kim, W. J.

Hwang. – Text: electronic // Applied Sciences. – 2019. – Vol. 9. - №17. – P. 3556. – URL: <https://www.mdpi.com/2076-3417/9/17/3556> (дата обращения: 7.05.2024).

41. Virtual reality tasks with eye tracking for mild spatial neglect assessment: a pilot study with acute stroke patients / J. Uimonen, S. Villarreal, S. Laari [и др.] // Frontiers in Psychology. – 2024. – Т. 15. – Virtual reality tasks with eye tracking for mild spatial neglect assessment. – С. 1319944.

42. Development and clinical trial of virtual reality-based cognitive assessment in people with stroke: preliminary study / Y. J. Kang, J. Ku, K. Han [и др.] // Cyberpsychology & Behavior: The Impact of the Internet, Multimedia and Virtual Reality on Behavior and Society. – 2008. – Т. 11. – Development and clinical trial of virtual reality-based cognitive assessment in people with stroke. – № 3. – С. 329-339.

43. NeuroAIreh@b: an artificial intelligence-based methodology for personalized and adaptive neurorehabilitation / A. L. Faria, Y. Almeida, D. Branco [и др.] // Frontiers in Neurology. – 2023. – Т. 14. – NeuroAIreh@b. – С. 1258323.

44. Suicidal Ideation / B. Harmer, S. Lee, A. Rizvi, A. Saadabadi. – Текст : электронный // StatPearls. – Treasure Island (FL) : StatPearls Publishing, 2024. – URL: <http://www.ncbi.nlm.nih.gov/books/NBK565877/> (дата обращения: 1.05.2024).

45. Social and olfactory experiences modify neuronal morphology of orbital frontal cortex / D. A. Hamilton, G. Silasi, C. M. Magcalas [и др.] // Behavioral Neuroscience. – 2020. – Т. 134. – № 1. – С. 59-68.