

ДЕДКОВ А.Е.,

Российский университет дружбы народов, г. Москва, Россия, e-mail: dedkov.ae@yandex.ru

АНДРИКОВ Д.А.,

к.т.н., доцент, Российский университет дружбы народов, г. Москва, Россия, e-mail: andrikov-da@rudn.ru

ХРАМОВ А.Е.,

д.ф.-м.н., профессор, БФУ им. И. Канта, г. Калининград, Россия, e-mail: hramovae@gmail.com

ОБЗОР СПОСОБОВ ИЗМЕРЕНИЯ КОГНИТИВНОЙ НАГРУЗКИ МОЗГА И МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ ДЛЯ ИХ ИДЕНТИФИКАЦИИ НА ОСНОВЕ ДАННЫХ ЭЭГ

DOI: 10.25881/18110193_2024_3_20

Аннотация. Цель данного обзора заключается в рассмотрении и анализе методов измерения когнитивной нагрузки, а также подходов к использованию методов машинного обучения для идентификации данных ЭЭГ.

Материалы и методы. В обзоре систематизированы и обобщены сведения по рассматриваемой теме. Поиск научных статей проведен в библиографических базах данных: eLIBRARY, ScienceDirect, Scopus.

Результаты. В данном обзоре были рассмотрены способы измерения когнитивной нагрузки мозга, современные устройства для записи ЭЭГ, методы преобразования, извлечения и классификации признаков из полученных сигналов ЭЭГ.

Выводы. С появлением новых носимых устройств для получения и обработки сигналов ЭЭГ появляется потребность в разработке новых подходов к использованию машинного обучения для идентификации когнитивных процессов мозга.

Ключевые слова: методы извлечения признаков ЭЭГ; методы измерения когнитивной нагрузки; методы преобразование сигналов ЭЭГ; методы классификации признаков ЭЭГ.

Для цитирования: Дедков А.Е., Андриков Д. А., Храмов А.Е. Обзор способов измерения когнитивной нагрузки мозга и методов машинного обучения для их идентификации на основе данных ЭЭГ. Врач и информационные технологии. 2024; 3: 20-31. doi: 10.25881/18110193_2024_3_20.

DEDKOV A.E.,

RUDN, Moscow, Russia, e-mail: dedkov.ae@yandex.ru

ANDRIKOV D.A.,

PhD, Associate Professor, RUDN, Moscow, Russia, e-mail: andrikov-da@rudn.ru

HRAMOV A.E.,

DSc., Professor, Immanuel Kant Baltic Federal University, Kaliningrad, Russia, e-mail: aekhramov@kantiana.ru

A REVIEW OF WAYS TO MEASURE BRAIN COGNITIVE LOAD AND MACHINE LEARNING METHODS FOR THEIR IDENTIFICATION FROM EEG DATA

DOI: 10.25881/18110193_2024_3_20

Abstract. *Aim.* The purpose of this article is review and analyze methods for measuring cognitive load, as well as approaches to using machine learning techniques to identify EEG data.

Materials and methods. The review systematizes and summarizes the information on the topic under consideration. Scientific articles were searched in bibliographic databases: eLIBRARY, ScienceDirect, Scopus.

Results. This review focused on ways to measure the cognitive load of the brain, modern EEG recording devices, and methods for transforming, extracting, and classifying features from acquired EEG signals.

Conclusion. With new wearable devices available for acquiring and processing EEG signals, there is a need to develop new approaches for using machine learning to identify cognitive brain processes.

Keywords: methods for extracting EEG signs; methods for measuring cognitive load; methods for converting EEG signals; methods for classifying EEG signs.

For citation: Dedkov A.E., Andrikov D.A., Hramov A.E. A review of ways to measure brain cognitive load and machine learning methods for their identification from EEG data. *Medical doctor and information technology.* 2024; 3: 20-31. doi: 10.25881/18110193_2024_3_20.

ВВЕДЕНИЕ

В эпоху развития цифровых технологий в здравоохранении с учетом аспектов регулирования использования медицинских данных [1] появляются возможности для создания новых носимых устройств контроля состояния здоровья [2], а современные методы обработки данных и алгоритмы машинного обучения открывают перед исследователями, медицинскими кибернетиками новые возможности, в том числе в задаче идентификации когнитивных процессов мозга.

Для диагностики и идентификации процессов в мозге используются различные психофизиологические методы визуализации. Одним из таких методов является электроэнцефалография (ЭЭГ).

ЭЭГ – метод исследования головного мозга, основанный на регистрации его электрических потенциалов [3].

Американской академией неврологии в 1997 году был опубликован отчет [4], в котором была рассмотрена эффективность использования количественных методов в аналитике ЭЭГ. В 1999 году в работе [5] было показано, что колебания ЭЭГ в альфа- и тета-диапазоне отражают когнитивные характеристики и производительность памяти.

В работе [6] было продемонстрировано, что динамика волновых ритмов головного мозга коррелирует со средним временем отклика при выполнении задачи рабочей памяти. Данный факт позволяет использовать этот биомаркер для предсказания снижения когнитивных способностей на основе динамики волнового ритма.

В последнее время виден значительный рост числа статей, посвященных применению ИИ в медицине, в том числе и нейродиагностики [7]. Применение таких подходов как ML/DL дает возможности для построения гибких систем для классификации данных ЭЭГ, в том числе и систем идентификации когнитивной нагрузки мозга.

Под когнитивной нагрузкой мозга понимается длительный мыслительный процесс, концентрация и вовлеченность при выполнении задач. В ходе практически любой когнитивной нагрузки у человека формируются или реконфигурируются функциональные сети в его головном мозге, структура и размер которых определяется типом

активности. Так, для простых академических заданий (например, устный счет, визуальный поиск различий на изображении и упражнения на запоминание чисел) можно выявить характерную функциональную сеть, для чего необходим статистический анализ в группе испытуемых. Изучение функциональных сетей, формирующихся в головном мозге, будет проводиться на базе результатов электроэнцефалографических (ЭЭГ) исследований. Для этого ЭЭГ-сигналы будут регистрироваться в процессе решения человеком поставленных задач, после чего к ним будут применяться современные методы анализа больших данных для оценки динамических параметров (мощность альфа-, бета-ритмов), так и квазистатические показатели (индивидуальный альфа-ритм и индекс утомления). Данный показатель может быть использован в практике образовательного учреждения для оценки эффективности индивидуальной траектории обучения на основе оценки реакции мозга в ходе академического процесса. В работе [8] в ходе исследования было показано, что длительная когнитивная нагрузка влияет на снижение самочувствия и активность испытуемого.

В исследовании [9] был выявлен универсальный биомаркер, основанный на вычислении дисперсии соотношения энергий альфа- и бета-ритмов в регистрируемых ЭЭГ-сигналах. Было показано, что возможно выделить оптимальную и минимально необходимую конфигурацию регистрирующих электродов, которая будет содержать наиболее значимую информацию о состоянии обучающегося.

В работе [10] было обнаружено увеличение количества морганий средней и длинной длительности при продолжительной монотонной когнитивной нагрузке, а также уменьшение среднего размера зрачка и увеличение амплитуды его колебаний в процессе выполнения заданий.

Процесс получения данных в нейронауке осложнен жесткими условиями, продиктованными научным методом. Из-за этого возникают барьеры их применения в образовательных учреждениях [5].

Для повышения эффективности и индивидуализации образовательного процесса требуется выявление различных биомаркеров состояния обучающегося в данных полученных ЭЭГ. В

обзоре [5] представлена интеллектуальная система для контроля и корректировки процесса обучения младших школьников на базе интерфейса «мозг — компьютер». Система включает в себя три основных блока: портативный электроэнцефалограф, планшет с разработанной электронной образовательной средой (ЭОС) и управляющий компьютер (лэптоп) с программным модулем для считывания и первичной обработки данных ЭЭГ.

В работе [11] предложили нейроадаптивную систему с открытым контуром, направленную на оценку и улучшение когнитивных способностей студентов. Техническая часть данной нейроадаптивной системы состоит из устройства с сенсорным экраном (для сбора поведенческих данных) и устройства ЭЭГ (для сбора нейрофизиологических данных). Система позволяет получить измерения поведенческих характеристик и мозговой активности студента (оцененной ЭЭГ во время выполнения специально разработанных когнитивных тестов). Авторы отметили, что использование ЭЭГ является довольно затратным для образовательных учреждений и требует специальной подготовки персонала. В работе была предложена оценка когнитивных способностей без ЭЭГ, используя только поведенческие данные. В данном случае система дает более грубую, но все же разумную оценку когнитивных способностей.

В работе [12] был проведен анализ публикаций по применению ЭЭГ-гарнитур в образовании по годам и странам. Начиная с 2016 года виден резкий рост публикаций в данной области. Лидерами по количеству публикаций стали Китай и США. Отмечено, что в данных странах реализуются государственные проекты и программы в области исследования и продвижения современных инновационных нейротехнологий.

Цель данного обзора – систематизация и обобщение сведений о технологиях и методах для сбора, обработки и классификации данных ЭЭГ для дальнейшего использования полученной информации в процессе построения информационной системы идентификации когнитивной нагрузки мозга.

МАТЕРИАЛЫ И МЕТОДЫ

Поиск публикаций произведен в базах данных eLIBRARY, ScienceDirect, Scopus. В качестве

ключевых слов использовались: «методы измерения когнитивной нагрузки», «преобразование и извлечение признаков из полученных сигналов ЭЭГ»; «классификация сигналов ЭЭГ»; «преобразование Фурье и ЭЭГ»; «нейрообручи»; «вейвлет-преобразование и ЭЭГ»; «methods of measuring cognitive load»; «transformation and extraction of features from received EEG signals»; «classification of EEG signals»; «Fourier transform and EEG»; «wavelet-conversion and EEG».

Критерии включения статей в обзор:

- 1) методы машинного обучения для классификации данных ЭЭГ;
- 2) методы измерения когнитивной нагрузки;
- 3) современные устройства получения данных ЭЭГ;
- 4) методы преобразования и извлечения признаков из полученных сигналов ЭЭГ;
- 5) измерение когнитивной нагрузки в образовании.

Критерии исключения:

- 1) срок публикации, кроме статей относящимся к фундаментальным знаниям;
- 2) используются исследуемые методы и данные, но для решения другой задачи.

Период публикаций: 1999–2024 гг.

Всего было проанализировано 10237 публикации (eLIBRARY – 372, ScienceDirect – 9865), из которых отобрано 149, и 49 источников в итоге вошли в обзор.

Остальные источники были исключены по причине несоответствия теме применения методов (описывалось использование в других сферах и задачах). Небольшая часть исключена после анализа абстракта и связей/цитат.

РЕЗУЛЬТАТЫ

В результате исследования источников были рассмотрены современные устройства для записи ЭЭГ, способы преобразования и извлечения признаков ЭЭГ, а также методы их классификации.

На основе рассмотренных данных выделены следующие методы и технологии: нейрообручи на «сухих» электродах, как перспективная технология для получения данных ЭЭГ; вейвлеты для преобразования сигнала ЭЭГ; нейронные сети для классификации полученных данных, в частности архитектуры CNN, RNN и Transformer.

СОВРЕМЕННЫЕ УСТРОЙСТВА ДЛЯ ЗАПИСИ ЭЭГ

Существуют различные методы измерения когнитивной нагрузки [13]:

- субъективное шкалирование (SWAT, NASA-TLX, SMEQ, RSME). Данные измерения основаны на наблюдении и описании самим испытуемым когнитивной нагрузки во время выполнения конкретной задачи. Данные показания легко и недорого собрать, но существует и проблема, она заключается в том, что данные измерения субъективны, и испытуемым зачастую приходится прерываться на заполнение анкет в момент выполнения задач;
- психофизиология (ЭДА, ВСР, ЭЭГ, фМРТ). Данные показатели основаны на обнаружении физиологических изменений, которые связаны с когнитивным состоянием. Физиологические измерения требуют специализированного оборудования, а интерпретация полученных данных является не тривиальной задачей и требует специальных методов;
- анализ ошибок (показатели производительности и поведенческие показатели). Оценивается производительность в момент когнитивной нагрузки путем прогнозирования выполнения задачи. В данном подходе есть проблема, заключающаяся в невозможности определить, произошли изменения в производительности в момент выполнения задачи или это связано с другим процессом. Поведенческие показатели основаны на анализе различий в поведении в момент когнитивной нагрузки.

Для получения ЭЭГ используется инвазивное, недорогое и портативное оборудование. В то же время существуют такие проблемы как:

- надёжность полученных показателей;
- стандартизация шкалы для измерения ЭЭГ, использование и выбор которой не будет зависеть от использованного оборудования.

Запись результатов ЭЭГ может быть классифицирована на два типа: в базовом состоянии покоя и событийно потенциальный анализ во время выполнения когнитивных задач [13].

В статье [14] проведен анализ показателей ЭЭГ в различных работах по тематике измерения когнитивной нагрузки, и было сделано предположение, что есть положительная связь

между альфа-активностью и когнитивной нагрузкой, отрицательная – между бета-активностью и когнитивной нагрузкой. Так же был проведен эксперимент по измерению когнитивной нагрузки с использованием портативной нейрогарнитуры. Умственные усилия коррелировали с бета-частотой (F7) в лобной доле.

В работе [15] был проведен эксперимент по подбору оптимальных конфигураций электродов для решения различных задач. Для решения задач концентрации внимания предложено использовать одну из следующих комбинаций электродов: AF3-AF4, Fz-P3-Pz-P4, Fz-Fc1-Fc2-CP5-Pz-CP6 и Fz- Fc1-Fc2-C3-C4-P7-Pz-P8. Также предложены универсальные комбинации электродов для решения различных задач: P7-P8, AF3-AF4-PO3-PO4, AF3-AF4-P7-P8-PO3-PO4 и AF3-AF4-FC1-FC2-P3-P4-O1-O2.

В исследовании [8] было показано, что длительная когнитивная нагрузка наибольшим образом отражается в тета-диапазоне (в большинстве случаев регистрируется с максимумом в Fz, иногда в Pz), бета-диапазоне (максимум регистрируется в лобных отведениях F3, Fz, F4), нижнем альфа-диапазоне (в теменных областях с максимумом в Pz), альфа-диапазоне (в затылочной O1 и O2).

Таким образом, можно сделать вывод, что для измерения когнитивной нагрузки необходимо наличие следующих электродов: F3-Fz-F4-Pz-O1-O2.

С развитием современной электроники возникает возможность и потребность в новых носимых устройствах для контроля здоровья и хорошего самочувствия.

На данный момент на открытом рынке появляются нейрообручи различных производителей, например, BrainBit [16], Muse 2 [17], NeuroSky MindWave Mobile 2 [18], Neuroplay [19] для получения неинвазивных данных ЭЭГ.

Данные устройства уже имеют более портативный вид в отличие от классических устройств и могут быть использованы дома.

Далее рассмотрим сравнительную таблицу популярных нейрообручей, представленных на рынке.

Как видно из таблицы 1, нейрообручи не обладают полным набором необходимых электродов. В дальнейшем будет проведено исследование по выбору нейрообруча с оптимальной

Таблица 1 — Конфигурации электродов различных моделей нейрообручей

Название	Конфигурация электродов
Neuroplay	Fp1, Fp2, T3, T4, O1, O2
BrainBit	T3 и T4, O1 и O2
Muse 2	Fpz, AF7, AF8, TP9, and TP10
NeuroSky MindWave Mobile 2	Fp1 A1 (клипса на мочке уха)

конфигурацией электродов для решения задачи измерения когнитивной нагрузки мозга.

ПРЕОБРАЗОВАНИЕ И ИЗВЛЕЧЕНИЕ ПРИЗНАКОВ ИЗ ПОЛУЧЕННЫХ СИГНАЛОВ ЭЭГ

Необработанные данные, полученные в ходе измерения ЭЭГ, как правило могут содержать помехи: систематические артефакты и физиологические.

Содержащиеся помехи необходимо эффективно фильтровать для сохранения информации ЭЭГ без помех и артефактов. Данная фильтрация необходима для получения более достоверной информации [19].

Существуют следующие методы фильтрации данных и подавления шума: фильтрация Винера, частотная фильтрация, вейвлет-преобразования (WT), адаптивная фильтрация, регрессионные методы, методы слепого разделения источников (ICA, PCA) [19].

Для извлечения признаков используются различные методы: AutoEncoder (AE), анализ независимых компонент (ICA), метод главных компонент (PCA), вейвлет-преобразование (WT), преобразование Фурье (FT) и др. [21–25].

В исследовании [16] была реализована автоматическая классификация ICA-компонентов для независимого удаления артефактов в сигналах ЭЭГ. Классификатор основан на линейных методах и применим для различных вариаций размещения электродов и поддерживает автоматический анализ результатов.

В работе [21] авторами был разработан алгоритм подготовки данных для регрессионной модели, проведен исследовательский анализ данных и обучена регрессионная модель оценок восприимчивости к психическим расстройствам на основе количественных характеристик ЭЭГ. Данный подход показал получение более точного результата при правильной подготовке

для определенных исследований данных перед классификацией.

В работе [28] для генерации признаков использовались следующие методы: коэффициенты спектрального разложения Фурье, значения функции Альтера-Джонсона, SAX-BOP признаки, линейные корреляции и классические статистики. Был проведен анализ использования различных признаков для классификации, лучшие результаты показали модели, использующие в качестве признаков коэффициенты спектрального разложения Фурье.

При изучении ЭЭГ сигнала часто используют две разновидности оконного преобразования Фурье: дискретное и непрерывное оконное преобразование Фурье. Недостатком оконных преобразований является то, что при вычислении используется фиксированное временное окно, которое не адаптируемо к локальным свойствам сигнала [29].

На данный момент вейвлет-преобразования все шире используются для исследования когнитивных способностей мозга. Данный подход не имеет недостатков преобразования Фурье и позволяет предложить ему альтернативу.

Вейвлет-преобразования – это частотно-временной анализ, отражающий состояние сигнала или функции $f(t)$ на шкале (частота) и положении во времени [29].

В монографии [29] описывается применение вейвлет преобразования в исследованиях когнитивных процессов. Показаны различные способы его применения: метод корреляций вейвлетовых кривых для оценки степени синхронизации на коротких временных интервалах, сопоставимых со скоростью отдельных умственных операций; вейвлет преобразование на базе комплексного вейвлета Морле, с помощью которого восстанавливались вейвлетные поверхности модуля коэффициентов вейвлетного преобразования в полосе частот,

отображающих динамику амплитуды потенциалов коры в рассматриваемом частотном диапазоне; применение временного разрешения вейвлет преобразования для извлечения информации о быстрых изменениях формы вызванного потенциала в процессе умственной деятельности.

КЛАССИФИКАЦИЯ

Из анализа работ (Таблица 2) можно выделить следующие методы машинного обучения для классификации сигналов ЭЭГ: свёрточная нейронная сеть (CNN), рекуррентная нейронная сеть (RNN), многослойный перцептрон (MLP), линейный дискриминантный анализ (LDA), метод опорных векторов (SVM), метод k ближайших соседей (KNN), ядерный метод и их другие комбинации [30–44].

В исследовании [45] был рассмотрен процесс определения по ЭЭГ того, является ли активность мозга нормальной или не нормальной. Задача решена путем использования рекуррентных нейронных сетей (RNN) под названием ChronoNet, которые используются в области классификации изображений. Нейронная сеть напрямую принимала временные ряды ЭЭГ в качестве входных данных и успешно себя показала для классификации речевых команд.

В работе [46] было проведено сравнение четырех популярных моделей машинного и глубокого обучения. Для этого были использованы модели: CNN, MLP, GRU и LSTM. В качестве данных был взят датасет из EEG-BCI Motor Imagery Dataset, в котором записаны результаты по представлению движения рук и ног. В ходе эксперимента было установлено, что каналы F7, F8, FT7, FT8, T9, TP7, TP8, FC оказывают более сильное влияние на результат. Повторно

был проведен эксперимент, используя только данные каналы, и в результате удалось получить улучшение результатов исследуемых моделей.

Были получены следующие результаты: CNN – 88,8%, MLP – 85,7, GRU – 84% и LSTM 82,2%.

В работе [47] модель глубокого обучения с механизмом самовнимания (Transformer) в сочетании с нейронной сетью свертки (CNN) была успешно применена для декодирования сигналов ЭЭГ в интерфейсе (BCI) Motor Imagery (MI). Были предложены локальный и глобальный подходы на основе сверточного трансформатора для классификации MI-EEG. Локальный трансформаторный кодер объединяется для динамического извлечения временных признаков и восполнения недостатков модели CNN. Глобальный трансформаторный энкодер был объединен с Densely Connected Network для улучшения потока информации и их повторного использования для того, чтобы получить адекватные представления временных и пространственных признаков.

В общем виде классификаторы можно разделить на классические модели и модели глубокого обучения.

ОБСУЖДЕНИЕ И ВЫВОДЫ

В современных реалиях набирает популярность персонализированная парадигма обучения. Она основывается на нейродидактике, которая исследует закономерности психических функций мозга в процессе обучения. Одним из трендом трансформации образовательной системы станет нейрообразование [10].

Использование методов регистрации активности мозга сможет помочь в преподавании в школах, вузах и при обучении пожилых людей. В текущее время данный вид исследований не

Таблица 2 — Используемые методы машинного обучения в рассмотренных статьях

Исследование	Применяемый метод
[30, 37]	Градиентный бустинг (Gradient boosting)
[31, 37]	Свёрточная нейронная сеть (CNN)
[32, 34]	Линейный дискриминантный анализ (LDA)
[33, 37]	Сверточная долговременная краткосрочная память (ConvLSTM)
[40]	Алгоритм извлечения функции общего пространственного шаблона (FBCSP) и случайный лес (RF)
[36]	Bayesian learning of frequency bands (SBLFB)
[43, 44]	Метод опорных векторов (SVM)
[47]	Модель глубокого обучения с механизмом самовнимания (Transformer)

получил большого распространения из-за сложности технической реализации получения и оценки исследуемых данных. На данный момент исследований изменений мозга во время обучения довольно мало [5].

В результате исследования [9] было показано, что в оптимальную и минимально необходимую конфигурацию регистрирующих электродов, содержащую наиболее значимую информацию о состоянии обучающегося, входят теменные электроды, центрально-теменные, а также электроды лобного полюса, что позволяет сократить количество используемых электродов.

Уменьшение количества электродов дает возможность попытки использовать современные нейрогабитурны для оценки когнитивной нагрузки мозга.

По результатам проведенного обзора имеющих на текущий момент данных по теме измерения когнитивной нагрузки мозга и методов машинного обучения для их идентификации на основе данных ЭЭГ можно сделать несколько выводов.

Во-первых, появление на рынке современных габитур с «сухими» электродами, которые не требуют использования электропроводящего геля, позволяет упростить получение данных ЭЭГ у испытуемых.

Во-вторых, одним из наиболее популярных методов для преобразования сигнала ЭЭГ является вейвлет преобразование.

В-третьих, в последнее время все чаще для классификации ЭЭГ сигналов используются методы глубокого обучения. В частности, используются такие модели как RNN и LSTM. С появлением моделей, основанных на трансформерах, которые хорошо себя показали в задачах компьютерного зрения и обработки естественного языка, опубликованы попытки использования данной архитектуры для классификации данных ЭЭГ. Механизмы дополнительного внимания, используемые в данных моделях, могут помочь в решении данной задачи.

ЗАКЛЮЧЕНИЕ

Существует множество методов измерения когнитивной нагрузки, у всех методов есть свои достоинства и недостатки. В эпоху развития компьютерного анализа, а также появления новых портативных устройств для получения сигналов ЭЭГ, возникают возможности для обработки

большого числа данных и получения новых результатов, что дает потенциальный ресурс для быстрого анализа когнитивной нагрузки человека в условиях дома или офиса. Для решения данной задачи требуются новые подходы.

При работе с данными ЭЭГ перед исследователем встают вопросы о выборе метода для обработки и извлечения признаков (WT, ICA, PCA и другие), это связано с тем, что данные являются зашумленными и требуют обработки перед их исследованием. В рассмотренных исследованиях можно увидеть, что извлечение признаков происходит различными методами в зависимости от поставленной задачи, и выбранный способ значительно влияет на полученный результат.

Второй задачей при работе с данными является задача их классификации для нахождения связей и закономерностей в данных. При классификации данных используют различные алгоритмы машинного обучения (LDA, SVM, KNN, CNN, RNN, FS, CSP и другие), которые показали свою эффективность в решении такого типа задач.

В настоящее время архитектура «трансформеры с механизмом самовнимания» широко применяется в обработке естественного языка.

В работе [47] было продемонстрировано, что сочетание фильтров CNN и трансформаторных кодеров с локальными и глобальными структурами имеет преимущество в извлечении полного набора полезных функций из сигналов ЭЭГ. Данный подход с применением моделей трансформеров с механизмом самовнимания для классификации может быть перспективным при обработке данных, полученных при использовании ограниченного количества каналов.

Разработка систем, позволяющих оценивать когнитивную нагрузку, может позволить наблюдать за реакцией мозга в процессе обучения или работы, что в свою очередь даст возможность следить за утомляемостью обучающихся или сотрудников.

Конфликт интересов. Авторы заявляют об отсутствии конфликта интересов (The authors declare no conflict of interest).

Источники финансирования. Исследование выполнено при поддержке программы «Приоритет-2030» Министерства образования и науки Российской Федерации.

ЛИТЕРАТУРА/REFERENCES

1. Шарова Д.Е. и др. Анализ мирового опыта в регулировании и использовании медицинских данных для целей создания систем искусственного интеллекта на основе машинного обучения // Врачи и информационные технологии. – 2022. – №4. – С.28-39. [Sharova DE, et al. Analiz mirovogo opyta v regulirovanii ispol'zovaniya medicinskih dannyh dlya celej sozdaniya sistem iskusstvennogo intellekta na osnove mashinnogo obucheniya. Vrach i informacionnye tekhnologii. 2022; 4: 28-39. (In Russ.)]
2. Карпов О.Э., Храмов А.Е. Информационные технологии, вычислительные системы и искусственный интеллект в медицине. – М.: ДПК Пресс, 2022. – С.321. [Karpov OE, Hramov AE. Informacionnye tekhnologii, vychislitel'nye sistemy i iskusstvennyj intellekt v medicine. M.: DPK Press. 2022. P.321. (In Russ.)]
3. Зенков Л.Р. Клиническая электроэнцефалография (с элементами эпилептологии). М.: МЕДпресс-информ, 2012. [Zenkov LR. Klinicheskaya elektroencefalografiya (s elementami epileptologii). M.: MEDpress-inform. 2012. (In Russ.)]
4. Klimesch W. EEG alpha and theta oscillations reflect cognitive and memory performance: a review and analysis. Brain Research Reviews. 1999; 29(2): 169-195. doi:10.1016/S0165-0173(98)00056-3.
5. Khramova MV, Hramov AE, Fedorov AA. Current Trends in the Development of Neuroscientific Research in Education. Voprosy obrazovaniya. Educational Studies Moscow. 2023; 4. doi: 10.17323/vo-2023-16701.
6. Sheoran M, Kumar S, Chawla S. Methods of denoising of electroencephalogram signal: a review. International Journal of Biomedical Engineering and Technology. 2015; 18(4): 385-395. doi: 10.1504/IJBET.2015.071012.
7. Nuwer M. Assessment of digital EEG, quantitative EEG, and EEG brain mapping: Report of the American Academy of Neurology and the American Clinical Neurophysiology Society. Neurology. 2024; 1: 277-292. doi: 10.1212/WNL.49.1.277.
8. Поликанова И.С., Сергеев А.В. Влияние длительной когнитивной нагрузки на параметры ЭЭГ // Национальный психологический журнал. – 2014. – 1(13). – С.84-92. [Polikanova IS, Sergeev AV. Vliyanie dlitel'noj kognitivnoj nagruzki na parametry EEG. Nacional'nyj psihologicheskij zhurnal. 2014; 1(13): 84-92. (In Russ.)]
9. Смирнов Н.М. и др. Новый электроэнцефалографический маркер эффективности решения когнитивной задачи // Известия Российской академии наук. Серия физическая. – 2023. – 1(87). – С.129-133. [Smirnov NM, et al. Novyj elektroencefalograficheskij marker effektivnosti resheniya kognitivnoj zadachi. Izvestiya Rossijskoj akademii nauk. Seriya fizicheskaya. 2023; 1(87): 129-133. (In Russ.)]
10. Зеер Э.Ф. Нейродидактика-инновационный тренд персонализированного образования // Профессиональное образование и рынок труда. – 2021. – №4(47). – С.30-38. [Zeer EF. Neirodidaktika-innovacionnyj trend personalizirovannogo obrazovaniya. Professional'noe obrazovanie i rynek truda. 2021; 4(47): 30-38. (In Russ.)]
11. Grubov VV, Khramova MV, Goman S, et al. Open-loop neuroadaptive system for enhancing student's cognitive abilities in learning. IEEE Access. Published online 2024. Accessed June 30, 2024. Available at: <https://ieeexplore.ieee.org/abstract/document/10487923>.
12. Максимова М.В., Этюев Х.Х. Опыт применения ЭЭГ в образовании: анализ зарубежных исследований // Отечественная и зарубежная педагогика. – 2023. – 2(1). [Maksimova MV, Etuev HH. Opyt primeneniya eeg v obrazovanii: analiz zarubezhnyh issledovanij. Otechestvennaya i zarubezhnaya pedagogika. 2023; 2(1). (In Russ.)]
13. Meghdadi AH, Karić MS, Berka C. EEG analytics: benefits and challenges of data driven EEG biomarkers for neurodegenerative diseases. In: 2019 IEEE International Conference on Systems, Man and Cybernetics (SMC). IEEE; 2019:1280-1285. Accessed June 30, 2024. Available at: <https://ieeexplore.ieee.org/abstract/document/8914065>.
14. Örün Ö, Akbulut Y. Effect of multitasking, physical environment and electroencephalography use on cognitive load and retention. Computers in Human Behavior. 2019; 92: 216-229.

15. Park S, Han CH, Im CH. Design of wearable EEG devices specialized for passive brain – computer interface applications. *Sensors*. 2020; 20(16): 4572.
16. Самойлов В.А. и др. Использование мобильного нейроинтерфейса «BrainBit» для анализа профессиональных качеств сотрудника службы безопасности. 2021. – С.249-254. [Samojlov VA, et al. Ispol'zovanie mobil'nogo nejrointerfejsa «BrainBit» dlya analiza professional'nyh kachestv sotrudnika sluzhby bezopasnosti. 2021: 249-254. (In Russ.)]
17. Krigolson OE, Williams CC, Norton A, Hassall CD, Colino FL. Choosing MUSE: Validation of a low-cost, portable EEG system for ERP research. *Frontiers in neuroscience*. 2017; 11: 109.
18. Permana K, Wijaya SK, Prajitno P. Controlled wheelchair based on brain computer interface using Neurosky Mindwave Mobile 2. In: *AIP Conference Proceedings*. Vol 2168. AIP Publishing; 2019. Accessed June 30, 2024. Available at: <https://pubs.aip.org/aip/acp/article-abstract/2168/1/020022/611867>.
19. Корякин Ф.И., Сорочинский М.А. Возможности и педагогический потенциал нейроинтерфейсов (на примере NeuroPlay 6C). 2022. [Koryakin FI, Sorochinskij MA. Vozmozhnosti i pedagogicheskij potentsial nejrointerfejsov (na primere NeuroPlay 6C). 2022. (In Russ.)]
20. Ходашинский И.А. и др. Биометрические данные и методы машинного обучения в диагностике и мониторинге нейродегенеративных заболеваний: обзор // *Компьютерная оптика*. – 2022. – №6(46). – С.988-1020. [Hodashinskij IA, et al. Biometrichekie dannye i metody mashinnogo obucheniya v diagnostike i monitoringe nejrodegenerativnyh zabolevanij: obzor. *Komp'yuternaya optika*. 2022; 6(46): 988-1020. (In Russ.)]
21. Winkler I, Haufe S, Tangermann M. Automatic Classification of Artifactual ICA-Components for Artifact Removal in EEG Signals. *Behav Brain Funct*. 2011; 7(1): 30. doi: 10.1186/1744-9081-7-30.
22. Kottaimalai R, Rajasekaran MP, Selvam V, Kannapiran B. EEG signal classification using principal component analysis with neural network in brain computer interface applications. 2013 IEEE International Conference on Emerging Trends in Computing, Communication and Nanotechnology (ICECCN). IEEE; 2013: 227-231. Accessed June 30, 2024. Available at: <https://ieeexplore.ieee.org/abstract/document/6528498>.
23. Vincent P, Larochelle H, Bengio Y, Manzagol PA. Extracting and composing robust features with denoising autoencoders. In: *Proceedings of the 25th International Conference on Machine Learning – ICML'08*. ACM Press; 2008: 1096-1103. doi: 10.1145/1390156.1390294.
24. Li W, Zhang D, Xu Z. Palmprint identification by fourier transform. *Int J Patt Recogn Artif Intell*. 2002; 16(04): 417-432. doi: 10.1142/S0218001402001757.
25. Schiff SJ, Aldroubi A, Unser M, Sato S. Fast wavelet transformation of EEG. *Electroencephalography and clinical neurophysiology*. 1994; 91(6): 442-455.
26. De Ridder D, Kouropteva O, Okun O, Pietikäinen M, Duin RPW. Supervised Locally Linear Embedding. Kaynak O, Alpaydin E, Oja E, Xu L, eds. *Artificial Neural Networks and Neural Information Processing – ICANN/ICONIP*. 2003; 2714. *Lecture Notes in Computer Science*. Springer Berlin Heidelberg; 2003: 333-341. doi: 10.1007/3-540-44989-2_40.
27. Zavarzin E, Milakhina N, Rudych P, Savostyanov A. EEG Data Preprocessing for Assessing the Degree of Connectivity of Areas of the Human Brain Under Resting Conditions and their Application to the Diagnosis of Socially Significant Diseases. 2021 IEEE 22nd International Conference of Young Professionals in Electron Devices and Materials (EDM). IEEE; 2021: 582-585. Accessed June 30, 2024. Available at: <https://ieeexplore.ieee.org/abstract/document/9507667>.
28. Буданцев А.В., Скляр А.Я. Методы машинного распознавания команд в ЭЭГ-сигнале // *ИТ-Стандарт*. – 2021. – №3. – С.21-27. [Budancev AV, Sklyar AYA. Metody mashinnogo raspoznavaniya komand v EEG-signale. *IT-Standart*. 2021; 3: 21-27. (In Russ.)]
29. Hramov AE, Koronovskii AA, Makarov VA, Maksimenko VA, Pavlov AN, Sitnikova E. Wavelets in Neuroscience. Springer International Publishing; 2021. doi: 10.1007/978-3-030-75992-6.
30. Mirzaei S, Ghasemi P. EEG motor imagery classification using dynamic connectivity patterns and convolutional autoencoder. *Biomedical Signal Processing and Control*. 2021; 68: 102584.

31. Stas S. Hybrid convolutional-multilayer perceptron artificial neural network for person recognition by high gamma EEG features. 2022; 17(2): 192-196.
32. Hsu WY. EEG-based motor imagery classification using neuro-fuzzy prediction and wavelet fractal features. *Journal of Neuroscience Methods*. 2010; 189(2): 295-302.
33. Володин М.В., Седых И.А. Оценка применения ConvLSTM-нейронной сети для прогнозирования эпилептических припадков. 2023. [Volodin MV, Sedyh IA. Ocenka primeneniya ConvLSTM-nejronnoj seti dlya prognozirovaniya epilepticheskikh pripadkov. 2023. (In Russ.)]
34. Wu SL, Wu CW, Pal NR, Chen CY, Chen SA, Lin CT. Common spatial pattern and linear discriminant analysis for motor imagery classification. In: 2013 IEEE Symposium on Computational Intelligence, Cognitive Algorithms, Mind, and Brain (Ccmb). IEEE; 2013: 146-151. Accessed June 30, 2024. Available at: <https://ieeexplore.ieee.org/abstract/document/6609178>.
35. Капралов Н.В., Нагорнова Ж.В., Шемякина Н.В. Методы классификации ЭЭГ-паттернов вообразяемых движений // Информатика и автоматизация. – 2021. – №1(20). – С.94-132. [Kaprалov NV, Nagornova ZHV, SHemyakina NV. Metody klassifikacii EEG-patternov voobrazhaemykh dvizhenij. Informatika i avtomatizaciya. 2021; 1(20): 94-132. (In Russ.)]
36. Zhang Y, Wang Y, Jin J, Wang X. Sparse Bayesian Learning for Obtaining Sparsity of EEG Frequency Bands Based Feature Vectors in Motor Imagery Classification. *Int J Neur Syst*. 2017; 27(02): 1650032. doi: 10.1142/S0129065716500325.
37. Шанин И.А., Ступников С.А. Методы анализа данных электроэнцефалографии с применением сверточных и рекуррентных нейронных сетей // Системы и средства информатики. – 2021. – №2(31). – С.36-46. [SHanin IA, Stupnikov SA. Metody analiza dannyh elektroencefalografii s primeneniem svertochnyh i rekurrentnyh nejronnyh setej. Sistemy i sredstva informatiki. 2021; 2(31): 36-46. (In Russ.)]
38. Tabar YR, Halici U. A novel deep learning approach for classification of EEG motor imagery signals. *Journal of neural engineering*. 2016; 14(1): 016003.
39. Ямаев М.И., Шипицин С.П., Филатова Е.С. Нейронные сети для классификации ЭЭГ: от перцептрона до сверточной LSTM-сети, 2018. – С.765-768. [YАmaev MI, SHipicin SP, Filatova ES. Nejronnye seti dlya klassifikacii EEG: ot perceptrona do svertochnoj LSTM-seti, 2018. P.765-768. (In Russ.)]
40. Bentlemsan M, Zemouri ET, Bouchaffra D, Yahya-Zoubir B, Ferroudji K. Random forest and filter bank common spatial patterns for EEG-based motor imagery classification. In: 2014 5th International Conference on Intelligent Systems, Modelling and Simulation. IEEE. 2014: 235-238. Accessed June 30, 2024. Available at: <https://ieeexplore.ieee.org/abstract/document/7280913>.

41. Хабиб Ж.М.Т., Погуда А.А. Сравнение методов анализа настроений глубокого обучения, включая LSTM и машинное обучение // Открытое образование. – 2023. – №4(27). – С.60-71. [Habib ZHMT, Poguda AA. Sravnenie metodov analiza nastroenij glubokogo obucheniya, vklyuchaya LSTM i mashinnoe obuchenie. Otkrytoe obrazovanie. 2023; 4(27): 60-71. (In Russ.)]
42. Головкин В.А., Лаврентьева С.В. Нейросетевой анализ электроэнцефалограмм для обнаружения эпилептической активности. 2011. [Golovko VA, Lavrent'eva SV. Nejrosetevoj analiz elektroencefalogramm dlya obnaruzheniya epilepticheskoy aktivnosti. 2011. (In Russ.)]
43. Станкевич Л.А. и др. Классификация электроэнцефалографических паттернов вообразяемых движений пальцами руки для разработки интерфейса мозг-компьютер // Информатика и автоматизация. – 2015. – №40(3). – С.163-182. [Stankevich LA, et al. Klassifikaciya elektroencefalograficheskikh patternov voobrazaemykh dvizhenij pal'cami ruki dlya razrabotki interfejsa mozg-komp'yuter. Informatika i avtomatizaciya. 2015; 40(3): 163-182. (In Russ.)]
44. Гунделах Ф.В., Станкевич Л.А. Классификация сигналов мозга в неинвазивном интерфейсе «Мозг-компьютер» // Системный анализ в проектировании и управлении: сб науч. тр. XXI Международн. 2017. – С.305. [Gundelah FV, Stankevich LA. Klassifikaciya signalov mozga v nein vazivnom interfejse «Mozg-komp'yuter». Sistemnyj analiz v proektirovanii i upravlenii: sb nauch. tr. XXI Mezhdunar. 2017. P.305. (In Russ.)]
45. Roy S, Kiral-Kornek I, Harrer S. ChronoNet: A Deep Recurrent Neural Network for Abnormal EEG Identification. In: Riaño D, Wilk S, Ten Teije A, eds. Artificial Intelligence in Medicine. Lecture Notes in Computer Science. Springer International Publishing; 2019; 11526: 47-56. doi: 10.1007/978-3-030-21642-9_8.
46. Avola D, Cascio M, Cinque L, et al. Analyzing EEG Data with Machine and Deep Learning: A Benchmark. In: Sclaroff S, Distanto C, Leo M, Farinella GM, Tombari F, eds. Image Analysis and Processing – ICIAP 2022. Lecture Notes in Computer Science. Springer International Publishing. 2022; 13231: 335-345. doi: 10.1007/978-3-031-06427-2_28.
47. Zhang J, Li K, Yang B, Han X. Local and global convolutional transformer-based motor imagery EEG classification. Frontiers in Neuroscience. 2023; 17: 1219988.