

АНАЛИЗ ВНИМАНИЯ ЧЕЛОВЕКА НА ОСНОВЕ ДАННЫХ ЭЭГ С ИСПОЛЬЗОВАНИЕМ МАШИННОГО ОБУЧЕНИЯ

ANALYSIS OF HUMAN ATTENTION BASED ON EEG DATA USING MACHINE LEARNING

K. Uvarov

Summary. The article provides an overview of modern methods for analyzing human attention based on electroencephalography data using machine learning algorithms. The key methods of EEG data processing and feature extraction are considered. The main methods and algorithms of machine learning that are used to analyze human attention based on EEG data are also considered.

Keywords: attention, electroencephalography, machine learning, data preprocessing, state classification, and deep learning.

Уваров Кирилл Андреевич

Аспирант, Санкт-Петербургский государственный
электротехнический университет
«ЛЭТИ» им. В.И. Ульянова (Ленина)
uvarovkirill73@gmail.com

Аннотация. В статье представлен обзор современных методов анализа внимания человека на основе данных электроэнцефалографии с использованием алгоритмов машинного обучения. Рассмотрены ключевые методы обработки ЭЭГ-данных и извлечения признаков. Также рассмотрены основные методы и алгоритмы машинного обучения, которые используются для анализа внимания человека на основе данных ЭЭГ.

Ключевые слова: внимание, электроэнцефалография, машинное обучение, предобработка данных, классификация состояний, глубокое обучение.

Введение

Внимание представляет собой одну из ключевых когнитивных функций, обеспечивающих эффективное взаимодействие человека с окружающим миром. Оно позволяет фокусироваться на важных аспектах информации, игнорируя второстепенные стимулы, что критически важно, как в повседневной жизни, так и в профессиональной деятельности. В условиях современного общества, характеризующегося высокой информационной насыщенностью, исследования внимания приобретают всё большую значимость. Они находят применение в таких областях, как медицина, образование, маркетинг, разработка интерфейсов и даже в сфере развлечений.

Одной из наиболее важных областей, где контроль внимания играет ключевую роль, является транспорт. В частности, вождение автомобиля, управление воздушным судном или другими сложными механизмами требует постоянной концентрации и быстрого реагирования на изменяющиеся условия. Недостаток внимания, вызванный усталостью, стрессом или другими факторами, является одной из основных причин аварий и катастроф. По данным Всемирной организации здравоохранения (ВОЗ), ежегодно в результате дорожно-транспортных происшествий погибает около 1,3 миллиона человек, при этом значительная часть таких инцидентов связана с недостаточной внимательностью водителей [1].

Одним из наиболее перспективных методов изучения внимания является анализ электроэнцефалографических (ЭЭГ) данных. ЭЭГ предоставляет возможность регистрировать электрическую активность головного

мозга с высокой временной разрешающей способностью, что делает её незаменимым инструментом для исследования динамических процессов, связанных с вниманием. Однако работа с ЭЭГ-данными сопряжена с рядом вызовов: сигнал имеет сложную структуру, чувствителен к шумам и артефактам, а его интерпретация требует глубоких знаний нейрофизиологии и специализированных аналитических методов.

Машинное обучение (МО) стало мощным инструментом, позволяющим автоматизировать обработку и анализ сложных биомедицинских данных, таких как ЭЭГ. Использование методов машинного обучения открывает новые горизонты в исследованиях внимания, позволяя строить точные и надёжные модели классификации когнитивных состояний. Ключевыми преимуществами машинного обучения являются способность к обработке больших объёмов данных, выявление скрытых закономерностей и адаптивность. Тем не менее, применение МО в контексте анализа ЭЭГ связано с рядом ограничений, включая сложность выбора подходящих алгоритмов, необходимость предварительной обработки данных и высокую вычислительную стоимость.

Цель данного обзора заключается в обобщении и анализе существующих подходов к оценке внимания человека на основе данных ЭЭГ и использования методов машинного обучения для анализа данных ЭЭГ. В рамках данного обзора поднимаются следующие ключевые вопросы:

1. Какие подходы к предварительной обработке данных являются наиболее подходящими для устранения шумов и артефактов в ЭЭГ?

2. Какие признаки ЭЭГ используются для оценки внимания и как их вычисляют?
3. Какие методы машинного обучения наиболее эффективны для анализа ЭЭГ-данных с целью определения внимания?
4. Какие ограничения существуют у современных методов анализа внимания на основе ЭЭГ, и как их можно преодолеть?

Ответы на эти вопросы помогут не только выявить существующие тенденции, но и наметить пути для дальнейших исследований в данной области.

Структура обзора. Настоящая работа состоит из нескольких разделов, каждый из которых посвящён определённому аспекту обзора. В первом разделе описываются современные тенденции по исследованию внимания. Основная часть работы посвящена обзору основных методов предобработки данных ЭЭГ, методов извлечения признаков ЭЭГ, а также методов машинного обучения, которые использовались в работах. В заключительном разделе поднимаются основные проблемы, ограничения и перспективы исследований в данной области. Таким образом, данный обзор не только представляет собой обобщение существующих знаний, но и служит ориентиром для дальнейших исследований в области применения методов машинного обучения для анализа ЭЭГ с целью определения уровня внимания человека.

Направления исследований в области анализа внимания. Под термином внимание понимают различные аспекты когнитивной функции внимания. Из-за этого, в исследованиях по теме внимания часто рассматри-

вают только какой-то определенный аспект внимания. Для оценки основных направлений в области внимания был проведен следующий поиск статей: производился поиск исследований в онлайн-базах данных ScienceDirect и PubMed. Поиск был произведен, используя фильтрацию по названию, аннотации и ключевым словам. Для поиска использовался запрос «(«EEG» OR «Electroencephalography» OR «Electroencephalogram») AND «attention» AND «Machine Learning»». После обзора результатов поиска можно выделить несколько направлений, над которыми в последнее время наиболее активно работают ученые. Как показано на рис. 1, большинство статей, связанных с областью внимания, опубликованных за последние 5 лет, были посвящены в основном классификации уровней внимания (30 %) и слуховому вниманию (25 %). Также было проведено много исследований, посвященных вниманию как таковому, включая исследования по распределению внимания, его ориентации и механизмам внимания. Остальные исследования касались пространственного внимания (9 %), зрительного внимания (7 %), устойчивого внимания (5 %), бдительности (5 %) и избирательного внимания (1 %) [2]. Для данного обзора отбирались работы, в которых рассматривается задача классификации уровня внимания. Данная задача, как можно заметить по статистике одна из самых актуальных задача по исследованию внимания на данный момент. Исследования по классификации уровней внимания в основном включают в себя классификацию состояний внимания, обнаружение отвлечения и обнаружение блуждания ума.

Доступные наборы данных. Одной из значительных трудностей в работе с ЭЭГ является обеспечение высокого качества и надежности данных. Для их получения




Рис. 1. Основные направления научных работ по исследованию внимания

исследователи могут выбирать между двумя основными методами: применением уже существующих наборов данных или самостоятельным сбором данных ЭЭГ. В таблице 1 приведены примеры общедоступных наборов данных, которые могут быть полезны для анализа внимания с использованием ЭЭГ. Согласно проведенному анализу, примерно 13.6 % научных работ опирались на готовые данные, тогда как 86.4 % авторов предпочли собирать данные самостоятельно.

Предобработка данных ЭЭГ. Прежде чем применять методы машинного обучения для анализа ЭЭГ-данных, необходимо выполнить предварительную обработку сигналов. Этот этап играет ключевую роль в обеспечении качества и надёжности анализа, так как позволяет устранить шумы, артефакты и другие помехи, которые могут исказить результаты.

Рассмотрим основные методы предобработки данных, которые используются в рассматриваемых работах.

Таблица 1.

Примеры общедоступных наборов данных ЭЭГ для исследования внимания

Статья	Количество участников	Частота дискретизации, Гц	Цель исследования, для которого собирались данные
[3]	23	1000	Оценка бдительности при вождении
[4]	18	250	Исследование пространственного внимания
[5]	30	1000	Определение состояния внимания
[6]	6	128	Определение состояния внимания
[7]	48	1000	Исследование избирательного внимания

Фильтрация сигналов по частотам. Фильтрация по частотам основана на том, что любой сигнал можно представить в виде суммы синусоидальных колебаний с разными частотами (спектр сигнала). Фильтр — это устройство или алгоритм, который изменяет амплитуду и фазу этих частотных компонент, чтобы выделить или подавить определённые частоты. Наиболее распространёнными методами фильтрации являются:

- Фильтр низких частот (ФНЧ, Low-Pass Filter, LPF): Пропускает частоты ниже определённой границы (частоты среза) и подавляет частоты выше неё.
- Фильтр высоких частот (ФВЧ, High-Pass Filter, HPF): Пропускает частоты выше частоты среза и подавляет низкие частоты.

- Полосовой фильтр (Band-Pass Filter, BPF): Пропускает частоты в определённом диапазоне (полосе) и подавляет частоты за её пределами.
- Режекторный фильтр (Band-Stop Filter, BSF): Подавляет частоты в определённом диапазоне и пропускает все остальные.
- Гребенчатый фильтр (Comb Filter): Подавляет или усиливает частоты на определённых интервалах, создавая характерный «гребенчатый» эффект.

В таблице 2 представлены диапазоны частот для фильтрации данных, которые использовались в работах. Наиболее часто используемым методом является полосовой фильтр, который удаляет посторонние шумы, удерживая сигналы в определенном диапазоне частот. Полосовой фильтр обычно реализуется путем объединения фильтра верхних частот с фильтром нижних частот. В этой комбинации порог фильтрации нижних частот обычно колеблется от 15 Гц до 70 Гц, причем наиболее распространенным значением является 50 Гц. Фильтры верхних частот часто устанавливаются на частоте 1 Гц и 0,5 Гц, в то время как в некоторых исследованиях фильтр верхних частот не применяется. Также в некоторых работах используется режекторный фильтр для частоты 50 Гц для фильтрации артефактов, вызванных работой электрических сетей.

Таблица 2.

Диапазоны частот фильтрации, использованные в научных работах

Работа	Диапазон частот, используемых для фильтрации
[8]	0–40
[9]	1–15
[10]	2–8
[11]	1–50
[12]	1–70
[13]	1–50
[14]	1–30
[15]	1–32
[16]	0.5–50
[17]	0.5–50
[18]	0.5–60
[19]	1–50
[20]	8–30
[21]	0.5–50
[22]	–
[23]	1–50

Работа	Диапазон частот, используемых для фильтрации
[24]	1–50
[25]	0.5–49
[26]	0.1–60
[27]	1–50
[28]	0.5–50
[6]	0–18

Удаление каналов с искаженными данными. В данных ЭЭГ некоторые каналы могут быть «плохими» из-за плохого контакта электродов, шумов или артефактов. В некоторых случаях такие каналы убирают из набора данных. Альтернативным решением является интерполяция. Интерполяция позволяет восстановить данные в таких каналах на основе информации из соседних каналов.

ICA и PCA. ЭЭГ-сигналы часто содержат артефакты, связанные с движением глаз, морганием или мышечными сокращениями. В обработке данных ЭЭГ часто используются методы анализа данных, такие как ICA (Independent Component Analysis, анализ независимых компонент) и PCA (Principal Component Analysis, метод главных компонент). Эти методы позволяют выделять полезные компоненты сигнала, устранять артефакты и снижать размерность данных.

PCA — это метод снижения размерности данных, который преобразует исходные данные в новый набор ортогональных компонент, называемых главными компонентами. Главные компоненты упорядочены по убыванию их вклада в дисперсию данных. Первая главная компонента объясняет наибольшую дисперсию, вторая — следующую по величине, и так далее.

ICA — это метод разделения сигналов на независимые компоненты, которые статистически независимы друг от друга. В отличие от PCA, ICA ищет компоненты, которые не только ортогональны, но и максимально независимы.

В современных исследованиях часто используется комбинация методов предварительной обработки для достижения наилучших результатов. Это позволяет обеспечить максимальную точность анализа и повысить надёжность построенных моделей.

В таблице 3 представлены методы предобработки данных для каждой из работ. Как можно заметить из результатов в таблице 3, фильтрации частот является практически обязательным этапом предобработки данных. Также в качестве одного из основных методов предобработки данных является метод независимых компонент.

Таблица 3.

Примеры общедоступных наборов данных ЭЭГ для исследования внимания

Работа	Метод предобработки
[8]	Полосовой фильтр
[9]	Полосовой фильтр
[10]	Удаление каналов с искаженными данными, ICA
[11]	Полосовой фильтр
[12]	Полосовой фильтр
[13]	Полосовой фильтр
[14]	Удаление каналов с искаженными данными, полосовой фильтр, ICA
[15]	Полосовой фильтр, ручная обработка данных
[16]	Полосовой фильтр
[17]	Полосовой фильтр
[18]	Band-pass filter, linear method
[19]	Полосовой фильтр, ICA
[20]	Полосовой фильтр
[21]	Полосовой фильтр
[22]	—
[23]	Полосовой фильтр, ICA, режекторный фильтр
[24]	Полосовой фильтр
[25]	Полосовой фильтр
[26]	Полосовой фильтр, ICA, режекторный фильтр
[27]	Полосовой фильтр, ICA
[28]	Полосовой фильтр, ICA
[6]	Полосовой фильтр

Извлечение признаков. Обработка данных ЭЭГ часто связана с анализом большого количества признаков, которые могут быть извлечены из сигналов. Однако не все признаки одинаково полезны для решения конкретной задачи. Избыточность признаков может ухудшить качество моделей машинного обучения, увеличить время обучения и затруднить интерпретацию результатов. В этом разделе представлены основные виды признаков и методы их извлечения.

Признаки временной области. Анализ во временной области основан на исходных сигналах ЭЭГ или их статистических свойствах. Примерами таких признаков может быть: потенциалы, связанные с событиями (ПСС), пиковое значение амплитуды сигнала, размах амплитуды (раз-

ница между максимумом и минимум), параметры Хьюрта, среднее значение, стандартное отклонение, эксцесс, перекося, дисперсия и т.д.

Признаки частотной области. Анализ в частотной области отражает спектральные характеристики ЭЭГ, такие как мощность и распределение различных частотных диапазонов. Эти признаки получаются путём преобразования сигнала из временной области в частотную с использованием методов, таких как быстрое преобразование Фурье. Примером таких признаков может быть: спектральная мощность в определённых частотных диапазонах (дельта: 0.5–4 Гц, тета: 4–8 Гц, альфа: 8–13 Гц, бета: 13–30 Гц, гамма: 30–100 Гц), соотношение мощностей разных диапазонов (например, альфа/тета), доминирующая частота (частота с максимальной мощностью).

Признаки частотно-временной области. Временно-частотный анализ распознаёт характеристики как во временной, так и в частотной области, что позволяет фиксировать динамические изменения сигналов ЭЭГ в обеих областях. Методами для извлечения частотно-временных признаков обычно служат: вейвлет-преобразование, оконное преобразование Фурье, Преобразование Гильберта — Хуанга и др.

Пространственные признаки. Эти признаки учитывают распределение активности мозга по различным электродам. Признаки этой группы используются для изучения функциональной организации мозга и локализации активности. Примеры признаков: карты распределения амплитуды или мощности, локализация источников активности, корреляция между сигналами разных электродов.

Характеристики, связанные со связностью. Эти характеристики, такие как функциональная связность, дают представление о коллективных закономерностях связности сигналов ЭЭГ. Энтропии, такие как энтропия Шеннона и приближительная энтропия, количественно определяют неопределённость и случайность в наблюдаемых данных ЭЭГ.

Несмотря на разнообразие признаков, которые можно извлечь для анализа сигнала ЭЭГ, не существует фиксированных правил для выбора наилучших признаков ЭЭГ, поскольку большинство методов извлечения признаков основаны на знаниях о предметной области. По этой причине исследователи выбирают различные признаки для решения задач, связанных с анализом данных ЭЭГ. В таблице 4 представлены основные методы извлечения признаков, которые использовались в работах.

Алгоритмы машинного обучения. В данном разделе представлен обзор наиболее широко используемых алгоритмов машинного обучения для анализа сигналов

Таблица 4.

Методы извлечения признаков, используемые в работах

Работа	Метод извлечения признаков
[8]	Быстрое преобразование Фурье, дискретное преобразование Фурье
[9]	Преобразование Гильберта-Хуанга
[10]	ПСС, методы частотно-временного анализа
[11]	Оконное преобразование Фурье, спектральная плотность мощности
[12]	Оконное преобразование Фурье, спектральная плотность мощности
[13]	Временные признаки
[14]	Характеристики, связанные со связностью
[15]	Быстрое преобразование Фурье
[16]	–
[17]	–
[18]	Быстрое преобразование Фурье
[19]	Оконное преобразование Фурье
[20]	Спектральная плотность мощности
[21]	Спектральная плотность мощности
[22]	Характеристики, связанные со связностью, Спектральная плотность мощности
[23]	Характеристики, связанные со связностью. Спектральная плотность мощности
[24]	Быстрое преобразование Фурье
[25]	Характеристики, связанные со связностью
[26]	Спектральная плотность мощности, параметры Хьюрта и другие статистические параметры
[27]	Спектральная плотность мощности, быстрое преобразование Фурье
[28]	Быстрое преобразование Фурье
[6]	Оконное преобразование Фурье)

ЭЭГ. В рамках рассмотренных исследований методы машинного обучения были классифицированы на две основные категории: обучение с учителем и глубокое обучение.

Методы обучения с учителем опираются на предварительно размеченные наборы данных, в рамках которых алгоритм устанавливает корреляционные зависимости между входными признаками и соответствующими метками. Однако эффективность данных

методов существенно снижается при обработке высоко-размерных или слабоструктурированных данных, а также при работе с абстрактными признаками. В отличие от них, методы глубокого обучения обеспечивают автоматическое извлечение иерархических репрезентаций данных посредством многослойных нейронных сетей. Данный подход демонстрирует высокую эффективность при обработке объемных и многомерных наборов данных, включая задачи выделения сложных нелинейных зависимостей. В Таблице 5 приведен детализированный перечень методов машинного обучения, применявшихся в анализируемых исследованиях.

Таблица 5.

Методы извлечения признаков, используемые в работах

Работа	Метод машинного обучения
[8]	–
[9]	Обучение с учителем: SVM
[10]	Обучение с учителем: SVM
[11]	Глубокое обучение: ESN
[12]	Глубокое обучение: LSTM
[13]	Обучение с учителем: LDA
[14]	Обучение с учителем: SVM
[15]	Обучение с учителем: SVM, KNN, Random Forest
[16]	Обучение с учителем: SVM
[17]	–
[18]	Обучение с учителем: MLR, MVPA
[19]	Глубокое обучение: LSTM, CNN
[20]	Обучение с учителем: LDA
[21]	Глубокое обучение: CNN
[22]	Глубокое обучение: LSTM
[23]	Обучение с учителем: SVM, KNN, Naive Bayes classifier, Random Forest, Gradient Boosting
[24]	Обучение с учителем: SVM, LR, RR
[25]	Обучение с учителем: KNN, Naive Bayes classifier, SVM, LDA

Работа	Метод машинного обучения
[26]	Обучение с учителем: SVM, KNN, Random Forest
[27]	Глубокое обучение: LSTM
[28]	Обучение с учителем: SVM
[6]	Обучение с учителем: SVM KNN. Глубокое обучение: ANFIS

Методы машинного обучения с учителем

Традиционные методы машинного обучения демонстрируют значительную эффективность при классификации высокоразмерных нелинейных сигналов, что представляет особую ценность для анализа данных ЭЭГ. Согласно проведенному анализу, приблизительно 64% рассмотренных исследований применяли методы машинного обучения с учителем для задач классификации. Среди них наибольшее распространение получил метод опорных векторов (Support Vector Machine, SVM). Также для классификации использовались методы: метод K-ближайших соседей (K-Nearest Neighbors, KNN), алгоритм случайного леса (Random Forest), Naive Bayes classifier, Gradient Boosting.

Методы глубокого обучения

С развитием методов глубокого обучения во многих статьях, посвященных исследованиям ЭЭГ, были применены модели глубокого обучения для анализа ЭЭГ-сигналов. Модели глубокого обучения, разработанные для анализа внимания, основаны на нескольких базовых моделях, с некоторыми изменениями в структуре или вводимых данных. Основными структурами этих моделей являются CNN и LSTM.

Заключение

В рамках этой работы был проведен обзор работ по анализу внимания человека на основе данных ЭЭГ и с помощью методов машинного обучения. В рамках обзора были выделены основные методы предварительной обработки данных ЭЭГ, методы выделения признаков и проведен обзор основных алгоритмов и методов машинного обучения, используемых для анализа внимания человека на основе данных ЭЭГ.

ЛИТЕРАТУРА

1. WHO. Global status report on road safety 2023 // World Health Organization, Geneva, Switzerland. 2023. Т. 15, № 4. 286 с.
2. Sun Q. и др. Attention Detection Using EEG Signals and Machine Learning: A Review // Mach. Intell. Res. 2025.
3. Zheng W.L., Lu B.L. A multimodal approach to estimating vigilance using EEG and forehead EOG // J. Neural Eng. 2017. Т. 14, № 2.
4. Reichert C. и др. Impact of Stimulus Features on the Performance of a Gaze-Independent Brain-Computer Interface Based on Covert Spatial Attention Shifts // Front. Neurosci. 2020. Т. 14, № December. С. 1–11.
5. Zhang Y. и др. An end-to-end 3D convolutional neural network for decoding attentive mental state // Neural Networks. Elsevier Ltd, 2021. Т. 144. С. 129–137.
6. Acı Ç.İ., Kaya M., Mishchenko Y. Distinguishing mental attention states of humans via an EEG-based passive BCI using machine learning methods // Expert Syst. Appl. 2019. Т. 134. С. 153–166.

7. Jose M.G. Penalver, David Lopez-Garcia, Blanca Aguado-Lopez, Carlos Gonzalez-Garcia C.G.-G. Anticipatory differences between Attention and Expectation.
8. van Son D. и др. Frontal EEG theta/beta ratio during mind wandering episodes // *Biol. Psychol. Elsevier B.V.*, 2019. Т. 140. С. 19–27.
9. Peng C.J. и др. An EEG-Based Attentiveness Recognition System Using Hilbert–Huang Transform and Support Vector Machine // *J. Med. Biol. Eng. Springer Berlin Heidelberg*, 2020. Т. 40, № 2. С. 230–238.
10. Jin C.Y., Borst J.P., van Vugt M.K. Predicting task-general mind-wandering with EEG // *Cogn. Affect. Behav. Neurosci. Cognitive, Affective, & Behavioral Neuroscience*, 2019. Т. 19, № 4. С. 1059–1073.
11. Jeong D.H., Jeong J. In-ear EEG based attention state classification using echo state network // *Brain Sci.* 2020. Т. 10, № 6. С. 1–23.
12. Zhang G., Etemad A. Capsule Attention for Multimodal EEG-EOG Representation Learning with Application to Driver Vigilance Estimation // *IEEE Trans. Neural Syst. Rehabil. Eng. IEEE*, 2021. Т. 29. С. 1138–1149.
13. Nlandu E. Aalborg Universitet Classification of EEG signals to identify variations in attention during motor task execution Classification of EEG signals to identify variations in attention during motor task execution Susan Aliakbarhosseinabadi a, Ernest Nlandu K. 2017.
14. Dhindsa K. и др. Individualized pattern recognition for detecting mind wandering from EEG during live lectures // *PLoS One*. 2019. Т. 14, № 9. С. 1–30.
15. Ko L.W. и др. Sustained attention in real classroom settings: An EEG study // *Front. Hum. Neurosci.* 2017. Т. 11, № July. С. 1–10.
16. Ni D., Wang S., Liu G. The EEG-Based Attention Analysis in Multimedia m-Learning // *Comput. Math. Methods Med. Hindawi*, 2020. Т. 2020.
17. Firdausi N.I. A High-Definition tDCS and EEG study on attention and vigilance: Brain stimulation mitigates the executive but not the arousal vigilance decrement // *Kaos GL Derg.* 2020. Т. 8, № 75. С. 147–154.
18. Torkamani-Azar M. и др. Prediction of Reaction Time and Vigilance Variability from Spatio-Spectral Features of Resting-State EEG in a Long-Sustained Attention Task // *IEEE J. Biomed. Heal. Informatics*. 2020. Т. 24, № 9. С. 2550–2558.
19. Chen M. и др. DeepFocus: Deep encoding brainwaves and emotions with multi-scenario behavior analytics for human attention enhancement // *IEEE Netw.* 2019. Т. 33, № 6. С. 70–77.
20. Vortmann L.M., Kroll F., Putze F. EEG-Based Classification of Internally— and Externally Directed Attention in an Augmented Reality Paradigm // *Front. Hum. Neurosci.* 2019. Т. 13, № October. С. 1–14.
21. Wu X., Shi C., Yan L. Driving Attention State Detection Based on GRU-EEGNet // *Sensors*. 2024. Т. 24, № 16. С. 1–21.
22. Shabbir Alam M., Zura A. Jalil S., Upreti K. Analyzing recognition of EEG based human attention and emotion using Machine learning // *Mater. Today Proc.* 2022. Т. 56, № November. С. 3349–3354.
23. Mir M. и др. Assessing neural markers of attention during exposure to construction noise using machine learning classification of electroencephalogram data // *Build. Environ. Elsevier Ltd*, 2024. Т. 261, № June. С. 111754.
24. Gupta S., Kumar P., Tekchandani R. A machine learning-based decision support system for temporal human cognitive state estimation during online education using wearable physiological monitoring devices // *Decis. Anal. J. Elsevier Inc.*, 2023. Т. 8, № April. С. 100280.
25. Alirezai M., Hajipour Sardouie S. Detection of Human Attention Using EEG Signals // 2017 24th Iran. Conf. Biomed. Eng. 2017 2nd Int. Iran. Conf. Biomed. Eng. ICBME 2017. 2018. № December.
26. Martínez Beltrán E.T. и др. SAFECAR: A Brain–Computer Interface and intelligent framework to detect drivers’ distractions // *Expert Syst. Appl. Elsevier Ltd*, 2022. Т. 203, № February. С. 117402.
27. Zeglache R., Labiod M.A., Mellouk A. Driver vigilance estimation with Bayesian LSTM Auto-encoder and XGBoost using EEG/EOG data // *IFAC-PapersOnLine. Elsevier Ltd*, 2022. Т. 55, № 8. С. 89–94.
28. Wang Y.K., Jung T.P., Lin C.T. EEG-Based Attention Tracking During Distracted Driving // *IEEE Trans. Neural Syst. Rehabil. Eng.* 2015. Т. 23, № 6. С. 1085–1094.

© Уваров Кирилл Андреевич (uvarovkirill73@gmail.com)

Журнал «Современная наука: актуальные проблемы теории и практики»