

ИНФОРМАЦИОННЫЕ
ТЕХНОЛОГИИ
И ТЕЛЕКОММУНИКАЦИИ

INFORMATION
TECHNOLOGIES
AND TELECOMMUNICATIONS

УДК 004.8

DOI: 10.17212/2782-2001-2024-3-77-89

Метод предсказания глазодвигательной активности на основе интеллектуального анализа данных мобильного портативного электроэнцефалографа*

В.Р. РОМАНИЮК

199178, г. Санкт-Петербург, 14-я линия, 39, Санкт-Петербургский институт ин-
форматики и автоматизации Российской академии наук

romaniukvr@yandex.ru

Глазодвигательные процессы, такие как фиксации и саккады, играют важнейшую роль в когнитивной деятельности человека, поскольку они связаны с такими функциями, как восприятие, внимание и принятие решений. Эти процессы активно применяются в ряде областей, включая системы человекокомпьютерного взаимодействия и нейрофизиологические исследования. Современные методы отслеживания движений глаз, основанные на оптических системах, обеспечивают высокую точность, но имеют ряд существенных ограничений. В связи с этим использование электроэнцефалографических (ЭЭГ) данных для анализа глазодвигательной активности становится перспективным направлением, так как ЭЭГ предоставляет информацию о нейронных процессах, лежащих в основе движений глаз. Это позволяет преодолеть многие ограничения оптических устройств, обеспечивая возможность мониторинга движений глаз без прямого визуального отслеживания. Целью данного исследования является разработка метода предсказания глазодвигательной активности на основе данных, собранных с мобильного ЭЭГ-устройства BrainBit. В работе использована нейронная сеть типа LSTM (долговременная кратковременная память). Результаты экспериментов показали, что предложенная модель обеспечивает высокую точность классификации основных типов глазодвигательной активности. Для фиксаций и саккад точность классификации достигла 91 %, что свидетельствует о высокой эффективности предложенной модели для этих типов движений. Однако классификация направленных движений глаз, таких как движения влево/вправо и вверх/вниз, оказалась более сложной задачей с точностью около 65 % и 63 % соответственно. Одной из ключевых проблем, выявленных в исследовании, стала высокая индивидуальная вариативность сигналов ЭЭГ между участниками. В связи с этим обучение модели было персонализировано для каждого участника эксперимента, что позволило повысить точность предсказаний для каждого отдельного человека. Таким образом, исследование демонстрирует потенциал использования ЭЭГ для анализа и предсказания движений глаз, особенно в контексте фиксаций и саккад.

Ключевые слова: отслеживание глаз, анализ ЭЭГ, методы глубокого обучения, носимый ЭЭГ, сигналы головного мозга, глазные движения, LSTM, нейронные сети

* Статья получена 10 апреля 2024 г.

ВВЕДЕНИЕ

Движения глаз играют ключевую роль во взаимодействии человека с окружающим миром, отражая широкий спектр когнитивных процессов, таких как внимание, восприятие и принятие решений. Способность отслеживать и классифицировать движения глаз открывает новые перспективы для применения в областях взаимодействия человека с компьютером, в нейрофизиологических исследованиях и технологиях поддержки человеческой деятельности. Традиционные методы отслеживания глаз, основанные на оптических устройствах для определения направления взгляда и глазной активности, обеспечивают ценные данные, но имеют ряд ограничений – зависимость от внешних камер и видимости маркеров, используемых для отслеживания [1].

Электроэнцефалография – неинвазивная технология записи электрической активности мозга, которая предоставляет обширные возможности для изучения нейронных процессов, лежащих в основе движений глаз. Данные ЭЭГ позволяют глубже понять физиологические и когнитивные состояния человека [2], что делает ее полезной в таких областях, как распознавание эмоций, оценка когнитивной нагрузки и исследования сна [3, 4]. В отличие от устройств оптического отслеживания глаз, которые фиксируют только видимые движения взгляда, ЭЭГ информирует об электрической активности мозга, что делает ее универсальным инструментом для исследования нейронных основ движений глаз и связанных процессов [5].

Современные исследования показали, что данные ЭЭГ могут быть использованы для классификации движений глаз. В работе [6] была продемонстрирована сильная корреляция между ЭЭГ и движениями глаз при выполнении различных задач. Это подтверждает гипотезу о том, что движения глаз и связанные с ними нейронные процессы могут быть предсказаны по данным ЭЭГ. Более того, такой метод, как электроокулография (ЭОГ), позволяет фиксировать корнеретинальные потенциалы, которые напрямую связаны с движениями глаз и могут служить основой для точной классификации фиксаций и саккад [7].

Появление мобильных ЭЭГ-устройств, таких как BrainBit, открывает новые возможности для использования ЭЭГ в повседневной жизни. В отличие от традиционных лабораторных ЭЭГ-систем, которые требуют использования гелей для улучшения контакта электродов с кожей и нахождения в контролируемых условиях, носимые устройства с сухими электродами более удобны для длительного мониторинга и могут использоваться в реальных условиях. Однако такие системы сталкиваются с рядом проблем, таких как шумы, возникающие при движении пользователя, и низкое качество сигнала по сравнению с лабораторными устройствами [8]. Тем не менее носимые ЭЭГ-устройства позволяют проводить исследования в более естественной среде [9], что расширяет возможности для их применения в системах человекокомпьютерного взаимодействия и нейротехнологических приложениях [10, 11].

Одним из направлений современных исследований является использование методов машинного обучения для анализа данных ЭЭГ и предсказания движений глаз. Глубокие нейронные сети, такие как сети LSTM (long short-term memory), оказались особенно эффективными при работе с последовательными данными, такими как ЭЭГ-сигналы [12, 13]. Сети LSTM могут учитывать временные зависимости в данных и обеспечивать высокую точность класси-

фикации. Примером успешного применения глубокого обучения для анализа ЭЭГ является работа [14], где была достигнута высокая точность классификации движений рук на основе данных ЭЭГ с использованием LSTM.

Несмотря на значительные успехи в анализе данных ЭЭГ, использование носимых устройств по-прежнему сопряжено с рядом проблем. В работе [15] обсуждаются трудности, связанные с низким качеством сигнала, получаемого с использованием носимых ЭЭГ-устройств, а также предложен метод их обработки – анализ независимых компонент (ICA). Авторы работы [16] представили алгоритм для удаления двигательных артефактов из спортивных упражнений, записанных при помощи мобильного ЭЭГ. Из этого следует, что специальные методы обработки сигнала позволяют уменьшить шумы и артефакты, возникающие при движении, и повысить качество анализа данных.

Таким образом, использование данных ЭЭГ для предсказания глазодвигательной активности является перспективным направлением исследований. Современные методы машинного обучения в сочетании с носимыми ЭЭГ-устройствами позволяют разрабатывать системы, которые могут применяться в реальных условиях для анализа движений глаз и когнитивных процессов. Применение подобных систем может быть востребовано в разработке технологий управления устройствами, таких как интерфейсы «мозг – компьютер», людьми, среди которых также могут быть пользователи с ограниченными возможностями. Например, системы на основе ЭЭГ могут использоваться для управления инвалидными колясками или роботизированными устройствами с использованием движения глаз. В настоящем исследовании предлагается метод классификации глазодвигательной активности с использованием данных, собранных с мобильного ЭЭГ-устройства BrainBit.

1. ПОСТАНОВКА ЗАДАЧИ

Предсказание движений глаз на основе данных ЭЭГ представляет собой задачу классификации временных последовательностей сигналов мозга. Движения глаз включают такие типы активности, как фиксации, саккады и направленные движения (влево, вправо, вверх, вниз). Каждому типу движения соответствует определенная последовательность электрической активности, зафиксированной с помощью ЭЭГ-датчиков, однако сигналы этих движений сильно зашумлены и могут накладываться на другие нейронные процессы.

Основной целью настоящего исследования является разработка модели машинного обучения, способной предсказывать движения глаз на основе данных, собранных с мобильного ЭЭГ-устройства.

Каждое движение глаза представляет собой временную последовательность данных ЭЭГ, записанных на нескольких каналах, с частотой дискретизации 250 Гц. В качестве эталона для обучения модели используются 2D-координаты взгляда, собранные с помощью оптического трекера глаз с частотой записи 100 Гц.

Задачу классификации можно формализовать следующим образом. Пусть $X = \{x_1, x_2, \dots, x_n\}$ – это набор временных последовательностей данных ЭЭГ, где каждая последовательность x_i представляет собой вектор признаков, полученных из ЭЭГ-сигналов за определенный временной интервал.

Цель состоит в том, чтобы для каждой последовательности x_i предсказать метку y_i , которая соответствует типу движения глаз.

Задача предсказания состоит в нахождении функции классификации f , которая отображает входные данные ЭЭГ в соответствующие классы движений глаз. Функция классификации f принимает на вход вектор признаков x_i и предсказывает соответствующую метку движения глаз y_i :

$$y_i = f(x_i, \theta),$$

где θ – набор параметров модели (например, весов нейронной сети), которые изменяются в процессе обучения. Для каждой подзадачи классификации метки y могут принимать значения принадлежности последовательности к какому-то классу подзадачи.

2. МЕТОДОЛОГИЯ

В этом исследовании изучается классификация движений глаз с использованием комбинации носимых устройств ЭЭГ и технологии оптической отслеживания взгляда. Основная цель – классифицировать различные типы движений глаз, включающие в себя фиксации, саккады и направленные движения: влево, вправо, вверх и вниз. Данные были собраны у участников, выполнявших различные задания, предназначенные для стимуляции различных моделей движений глаз. Затем эти данные были обработаны и использованы в алгоритмах глубокого обучения для точной классификации этих движений.

На рис. 1 представлена методология классификации движений глаз: от начального изучения данных и предварительной обработки до извлечения признаков и формирования последовательностей данных динамической длины, которые соответствуют различным типам движений глаз. Эти последовательности были использованы для обучения нейронной сети, нацеленной на классификацию движений. Все шаги методологии подробно описаны далее.

2.1. СБОР ДАННЫХ

Сбор данных был осуществлен с использованием двух основных устройств. Первое устройство – BrainBit, носимый электроэнцефалограф в виде головной повязки с четырьмя сухими электродами, записывающий исходный сигнал ЭЭГ с частотой 250 Гц и предоставляющий данные в вольтах. Второе устройство – Pupil Labs Invisible, система отслеживания взгляда в виде очков, записывающая 2D-координаты взгляда с частотой 100 Гц.

В эксперименте приняли участие 8 человек, выбранных без учета возраста, пола или состояния зрения.

Перед началом эксперимента каждому участнику надевалась головная повязка BrainBit и очки для отслеживания глаз Pupil Labs Invisible. Сбор данных проводился во время компьютерных сессий, в ходе которых участники сидели перед ноутбуком, как показано на рис. 2. Каждый сеанс длился около трех часов и включал выполнение различных задач, направленных на вызов разно-

образных движений глаз, таких как чтение текста с экрана, выполнение корректурной пробы Ландольта и простые компьютерные игры.

Рис. 1. Методология классификации движений глаз

Fig. 1. Eye movement classification methodology

Рис. 2. Установка для сбора данных

Fig. 2. Data collection setup

В общей сложности было записано 24 часа данных, однако некоторые временные интервалы данных были исключены из окончательного набора, так как в определенные моменты происходило нарушение подключения устройств или запись была нарушена по техническим причинам. Это могло быть связано, например, с потерей контакта электродов или с нарушением подключения к устройству. Такие сегменты данных были удалены для обеспечения достоверности анализа, что сократило получившееся время записи до 20 часов.

2.2. ПРЕДВАРИТЕЛЬНАЯ ОБРАБОТКА ДАННЫХ

Каждый источник данных содержал свои временные метки для записанных событий. Однако эти сигналы собирались с использованием разных устройств, и поэтому требовалась синхронизация данных. Разница во времени между записями составляла более 300 миллисекунд. Для устранения этого несоответствия была проведена ручная синхронизация путем выявления и выравнивания характерных событий, общих для обеих записей. В частности, движения глаз с высокой амплитудой, наблюдаемые при отслеживании взгляда, были обнаружены с помощью вычисления расстояния, пройденного глазом с момента предыдущей точки записи. Эти движения были выравнены с соответствующими сегментами в записях ЭЭГ, которые показывали колебания большой амплитуды, что обеспечивало выравнивание двух потоков данных на временной шкале. Пример этого процесса синхронизации показан на рис. 3, где выделено совпадение движений глаз с колебаниями ЭЭГ большой амплитуды.




Рис. 3. Пример синхронизации, показывающий координаты взгляда и сигнал ЭЭГ с найденной точкой синхронизации

Fig. 3. An example of synchronization showing the gaze coordinates and the EEG signal with the found synchronization point

Для улучшения качества данных ЭЭГ была применена предварительная обработка. Предварительная обработка данных ЭЭГ необходима, так как

исходные данные, получаемые с помощью ЭЭГ, часто содержат значительное количество шумов и артефактов, которые могут исказить результаты анализа. Эти помехи могут быть вызваны как внешними факторами, такими как электромагнитные наводки, так и внутренними, например движениями мышц. Без должной очистки интерпретация данных может привести к ошибочным выводам о нейрофизиологической активности.

Для повышения качества данных была применена фильтрация, в ходе которой использовался полосовой фильтр, пропускающий частоты ниже 40 Гц. Полосовой фильтр – это инструмент для обработки сигналов, который изолирует определенный диапазон частот, устраняя сигналы вне этого диапазона. Он работает по принципу подавления нежелательных частот, которые находятся за пределами установленной полосы пропускания. В данном случае фильтр настроен таким образом, чтобы пропускать только частоты ниже 40 Гц, устраняя высокочастотные компоненты, такие как электромиографические артефакты, т. е. шумы от активности мышц, и электромагнитные помехи. Этот процесс позволяет сохранить только те частоты, которые содержат значимую информацию о нейронной активности, улучшая соотношение сигнал / шум.

В отличие от стандартных методов, которые часто отсекают низкочастотные компоненты сигнала ниже 0,5...1,0 Гц, в настоящем исследовании эти компоненты были сохранены. Это обусловлено тем, что низкочастотные сигналы могут содержать важную информацию, связанную с движениями глаз и с другими физиологическими процессами, такими как мускульная активность в области лица. Мускульные активности, отслеживаемые при движении глаз, имеют характерную длительность от 0,1 до одной секунды, что соответствует частотному диапазону 0,5...10,0 Гц. При этом наиболее долгие компоненты оказываются в выделенной низкочастотной области. Таким образом, они относятся к частотам, которые традиционно отсекаются фильтрами, ориентированными на устранение медленных шумов, но в данном исследовании рассматриваются как источник полезной информации.

2.3. ИЗВЛЕЧЕНИЕ ПРИЗНАКОВ

Из данных отслеживания глаз было извлечено несколько признаков: расстояние между последовательными точками взгляда, скорость движений глаз и угловое направление этих движений. Эти признаки использовались для классификации движений глаз – фиксации, саккады и направленные движения (влево, вправо, вверх, вниз). Каждая последовательность движений глаз была соответствующим образом помечена.

С каждой последовательностью движений глаз ассоциировались соответствующие данные ЭЭГ, именуемые вызванным потенциалом (ERP). Для обеспечения качества сигнала ЭЭГ была проведена нормализация – это уменьшило вариативность данных между последовательностями. Нормализация включала корректировку исходных данных с учетом базовых смещений: в этом случае из данных вычиталась медиана последовательности и осуществлялось приведение к нормированным значениям, так как исходное значение напряжения на электроде достаточно низкое.

Также было проведено извлечение статистических признаков, таких как среднее, минимум, максимум и 90-й перцентиль. Эти статистические признаки

усилили различительные характеристики данных ЭЭГ, что способствовало более точной классификации движений глаз.

Движения глаз, как правило, связаны с активностью как мышц, так и мозга. Процессы в мозге могут начинаться до самого движения и продолжаться после него. Чтобы учесть это, границы выделенных сегментов ЭЭГ были расширены и включали дополнительные 0,1 секунды до и после каждого события движения глаз. Это позволило захватить как подготовительную, так и постсобытийную активность мозга. Процесс показан на рис. 4. Таким образом, каждая из последовательностей может быть длиной от 0,2 до 0,5 секунды. Это описывает вариативность физиологических процессов, соответствующих движению глаз, учитывая, что длительность саккад у человека может варьироваться от 20 до 200 миллисекунд в зависимости от амплитуды движения.

Для выполнения задачи классификации была использована нейронная сеть типа LSTM (долговременная кратковременная память). LSTM является специальной версией рекуррентной нейронной сети (RNN), разработанной для эффективной обработки последовательных данных с учетом долгосрочных зависимостей.

Эти сигналы имеют физиологическую природу, характеризуются динамическими изменениями и различной длиной последовательностей, что делает их анализ сложной задачей для стандартных методов. Именно принципы рекуррентных сетей, включая сохранение контекста и запоминание зависимостей между разными временными шагами, делают LSTM идеально подходящей для работы с такими данными. Обычные нейронные сети не могут эффективно учитывать переменную длину последовательностей, тогда как LSTM способна адаптироваться к этим изменениям благодаря своей структуре, которая включает механизмы памяти и управления забыванием информации.

Архитектура модели, используемой в исследовании, была спроектирована таким образом, чтобы входной размер данных соответствовал количеству выбранных каналов ЭЭГ плюс дополнительные статистические признаки. Данные обрабатываются с помощью сети LSTM, внутри которой использовались скрытые слои со 128 блоками, повторяющиеся в четырех слоях. Полносвязный (dense) слой после слоев LSTM обеспечивает преобразование выходных данных сети LSTM в предсказание принадлежности текущей последовательности к какому-то классу, что и является выходом модели.

Данные были разделены на обучающую, валидационную и тестовую выборки в соотношении 80/10/10. Для обучения модели использовалась функция потерь кросс-энтропии, которая оценивает разницу между предсказанными вероятностями классов и истинными метками. Оптимизация проводилась с использованием алгоритма Adam, который адаптирует скорость обучения для эффективного решения задач.

Чтобы стабилизировать обучение, использовался планировщик скорости обучения, который снижал ее на 10 % каждые три эпохи, – это помогло добиться более стабильного процесса обучения.

Модель обучалась для каждого участника по отдельности и могла классифицировать движения глаз только выбранного участника.




Рис. 4. Извлечение саккад с соответствующей последовательностью ЭЭГ и расширенными границами фильтра

Fig. 4. Saccade extraction with the appropriate EEG sequence and expanded filter boundaries

РЕЗУЛЬТАТЫ

Для оценки работы модели были выбраны метрики «точность» и «F1-score». Эти показатели вычислялись с использованием результатов работы модели при обработке тестовой выборки, не участвовавшей в ее обучении, для каждой задачи классификации у каждого участника: фиксации или саккады, движения влево или вправо, вверх или вниз. Результаты оценки представлены в таблице.

Результаты оценки модели для различных задач
Model evaluation results for different tasks

Участник	Фиксация / Саккада		Движения влево / вправо		Движения вверх / вниз	
	Точность, %	F1-score	Точность, %	F1-score	Точность, %	F1-score
1	91,99	0,92	63,17	0,644	61,49	0,601
2	89,61	0,937	61,89	0,646	62,82	0,616
3	90,19	0,931	59,95	0,644	60,99	0,611
4	86,75	0,951	65,56	0,675	60,96	0,624
5	88,91	0,948	64,13	0,631	63,01	0,623
6	87,45	0,928	62,71	0,651	59,87	0,605
7	85,64	0,939	65,44	0,667	63,10	0,623
8	88,91	0,933	63,8	0,670	61,68	0,611

Модель показывает стабильно высокие показатели в задаче классификации фиксации / саккада среди всех участников эксперимента. Также стабильные результаты получаются и по другим задачам, однако они имеют меньшую точность, что свидетельствует о затруднениях в способности их распознавания. Также наблюдается вариативность результатов между участниками, что может быть связано с индивидуальными особенностями движений глаз или с качеством данных. Среди участников выделяется участник 4, у которого большинство показателей оказались выше остальных, что может свидетельствовать об особенностях его поведения или записи данных.

Индивидуальные различия в электрической активности не позволили создать универсальную модель, подходящую для всех. К тому же классификация направленных движений (влево/вправо, вверх/вниз) оказалась затруднительной, так как они вызывают похожие изменения в сигналах ЭЭГ, что затрудняет их точное различение.

ЗАКЛЮЧЕНИЕ

В настоящей работе была исследована возможность классификации различных типов движений глаз на основе данных ЭЭГ, собранных с помощью мобильного электроэнцефалографа, с применением нейронных сетей типа LSTM. Результаты показали, что по ЭЭГ-сигналам можно различать фиксации, саккады и направленные движения (влево, вправо, вверх, вниз), однако существенным препятствием оказалась высокая вариативность сигналов ЭЭГ между участниками, что затруднило использование единой модели для всех и привело к использованию индивидуального обучения для каждого участника. Наибольшая точность была достигнута при классификации фиксаций и саккад. Направленные движения оказались сложнее для точного распознавания и имеют значительно меньшую точность.

Основное преимущество предложенного подхода заключается в способности модели обрабатывать последовательности разной длины, что делает ее адаптивной к различным типам движений глаз. Это открывает возможности для применения модели в реальном времени, например, в системах взаимодействия «человек – компьютер» или вспомогательных технологиях.

Главным ограничением является высокая индивидуальная вариативность ЭЭГ-сигналов между участниками. Будущие исследования могут включать использование таких методов, как перенос обучения (transfer learning), персонализация моделей или их адаптация для конкретных пользователей, чтобы улучшить точность классификации.

Перспективным направлением будущих исследований является расширение модели для отслеживания непрерывных координат взгляда, что позволит создать более точные решения для трекинга глаз в реальном времени.

СПИСОК ЛИТЕРАТУРЫ

1. Eye tracking in human interaction: Possibilities and limitations / N. Valtakari, I. Hooge, C. Viktorsson, P. Nystrom, T. Falck-Ytter, R. Hessels // *Behavior Research Methods*. – 2021. – Vol. 53 (3). – P. 1592–1608. – DOI: 10.3758/s13428-020-01517-x.
2. Сервис гибридного анализа электрической активности мозга и видеотрекинга состояния человека / Э.В. Глеклер, А.М. Кашевник, Н.В. Шемякина, Ж.В. Нагорнова, И.В. Брак, А.С. Станкевич // *Информационные технологии и вычислительные системы*. – 2023. – № 4. – С. 72–85. – DOI: 10.14357/20718632230407.
3. EEG-based detection of adverse mental state under multi-dimensional unsafe psychology for construction workers at height / Z. Li, X. Xiahou, G. Chen, S. Zhang, Q. Li // *Developments in the Built Environment*. – 2024. – Vol. 19. – P. 100513. – DOI: 10.1016/j.dibe.2024.100513.
4. Wang J., Wang Z., Liu G. Recording brain activity while listening to music using wearable EEG devices combined with bidirectional long short-term memory networks // *Alexandria Engineering Journal*. – 2024. – Vol. 109. – P. 1–10. – DOI: 10.1016/j.aej.2024.07.122.
5. Tracking gaze position from EEG: Exploring the possibility of an EEG-based virtual eye-tracker / R. Sun, A.S.K. Cheng, C. Chan, J. Hsiao, A.J. Privitera, J. Gao, C.-h. Fong, R. Ding, A.C. Tang // *Brain and Behavior*. – 2023. – Vol. 13 (10). – DOI: 10.1002/brb3.3205.
6. Neural correlation of EEG and eye movement in natural grasping intention estimation / C. Lin, C. Zhang, J. Xu, R. Liu, Y. Leng, C. Fu // *IEEE Transactions on Neural Systems and Rehabilitation Engineering*. – 2023. – Vol. 31. – P. 4329–4337.
7. Jia Y., Tyler C. Measurement of saccadic eye movements by electrooculography for simultaneous EEG recording // *Behavior Research Methods*. – 2019. – Vol. 51 (5). – P. 2139–2151. – DOI: 10.3758/s13428-019-01280-8.
8. Park S., Han C., Im C. Design of wearable EEG devices specialized for passive brain-computer interface applications // *Sensors (Switzerland)*. – 2020. – Vol. 20 (16). – P. 4572. – DOI: 10.3390/s20164572.
9. Quality assessment of single-channel EEG for wearable devices / F. Grosselin, X. Navarro-Sune, A. Vozzi, k. Pandremmenou, F.D.V. Fallani, Y. Attal, M. Chavez // *Sensors (Switzerland)*. – 2019. – Vol. 19 (3). – P. 601. – DOI: 10.3390/s19030601.
10. Mind the gap: State-of-the-art technologies and applications for EEG-based brain-computer interfaces / R. Portillo-Lara, B. Tahirbegi, C.A.R. Chapman, J.A. Goding, R.A. Green // *APL Bioengineering*. – 2021. – Vol. 5 (3). – P. 16. – DOI: 10.1063/5.0047237.
11. Gaming control using a wearable and wireless EEG-based brain-computer interface device with novel dry foam-based sensors / L. de Liao, C.Y. Chen, I.J. Wang, S.F. Chen, S.Y. Li, B.W. Chen, J.Y. Chang, C.T. Lin // *Journal of NeuroEngineering and Rehabilitation*. – 2012. – Vol. 9 (1). – DOI: 10.1186/1743-0003-9-5.
12. Deep learning in EEG: Advance of the last ten-year critical period / S. Gong, K. Xing, A. Cichocki, J. Li // *IEEE Transactions On Cognitive And Developmental Systems*. – 2022. – Vol. 14 (2). – P. 348–365. – DOI: 10.1109/TCDS.2021.3079712.
13. Deep learning-based construction equipment operators' mental fatigue classification using wearable EEG sensor data / I. Mehmood, H. Li, Y. Qarout, W. Umer, S. Anwer, H. Wu, M. Hussain, M. Fordjour Antwi-Afari // *Advanced Engineering Informatics*. – 2023. – Vol. 56. – DOI: 10.1016/j.aei.2023.101978.
14. Classification of hand movements from EEG using a deep attention-based LSTM network / G. Zhang, V. Davoodnia, A. Sepas-Moghaddam, Y. Zhang, A. Etemad // *IEEE Sensors Journal*. – 2019. – Vol. 20. – P. 3113–3122.
15. Klug M., Gramann K. Identifying key factors for improving ICA-based decomposition of EEG data in mobile and stationary experiments // *European Journal of Neuroscience*. – 2021. – Vol. 54 (12). – P. 8406–8420. – DOI: 10.1111/ejn.14992.

16. Removal of movement artefact for mobile EEG analysis in sports exercises / E. Butkeviciute, L. Bikulciene, T. Sidekerskiene, T. Blazauskas, R. Maskeliunas, R. Damasevicius, W. Wei // IEEE Access. – 2019. – Vol. 7. – P. 7206–7217. – DOI: 10.1109/ACCESS.2018.2890335.

Романюк Владимир Русланович, младший научный сотрудник лаборатории интегрированных систем автоматизации СПИИРАН. Научные интересы: машинное обучение, определение состояния человека. E-mail: romaniukvr@yandex.ru

Romanyuk Vladimir R., junior researcher at the laboratory of integrated automation systems, SPC RAS. His research interests include machine learning and human state recognition. E-mail: romaniukvr@yandex.ru

DOI: 10.17212/2782-2001-2024-3-77-89

Method for predicting eye movement activity based on intelligent data analysis from a mobile portable electroencephalograph *

V.R. ROMANYUK

St. Petersburg Institute for Informatics and Automation of the Russian Academy of Sciences, 14th Line, 39, St. Petersburg, 199178, Russian Federation

romaniukvr@yandex.ru

Abstract

Eye movement processes, such as fixations and saccades, play a crucial role in human cognitive activity as they are closely associated with functions such as perception, attention, and decision-making. These processes are actively applied in various fields, including human-computer interaction systems and neurophysiological research. Modern eye-tracking methods based on optical systems provide high accuracy but have several significant limitations. In this regard, the use of electroencephalographic (EEG) data for analyzing eye movement activity is becoming a promising direction, as EEG provides insights into the neural processes underlying eye movements. This allows many limitations of optical systems to be overcome, enabling the monitoring of eye movements without direct visual tracking. The goal of this study is to develop a method for predicting eye movement activity based on data collected from the BrainBit mobile EEG device. The study utilizes a long short-term memory (LSTM) neural network. Experimental results demonstrated that the proposed model achieves high accuracy in classifying the main types of eye movement activity. For fixations and saccades, the classification accuracy reached 91 %, indicating a high effectiveness of the model for these types of movements. However, classifying directed eye movements, such as left/right and up/down movements, proved to be a more challenging task, with an accuracy of about 65 % and 63 %, respectively. One of the key challenges identified in the study was the high individual variability of EEG signals between participants. As a result, the model training was personalized for each participant, which improved the accuracy of predictions for each individual. Thus, the study highlights the potential of using EEG for analyzing and predicting eye movements, particularly in the context of fixations and saccades.

Keywords: eye-tracking, EEG analysis, deep learning, wearable EEG, brain signals, eye movements, LSTM, neural networks

REFERENCES

1. Valtakari N., Hooge I., Viktorsson C., Nystrom P., Falck-Ytter T., Hessels R. Eye tracking in human interaction: Possibilities and limitations. *Behavior Research Methods*, 2021, vol. 53 (3), pp. 1592–1608. DOI: 10.3758/s13428-020-01517-x.
2. Glekler E.V., Kashevnik A.M., Shemyakina N.V., Nagornova Zh.V., Brak I.V., Stankevich A.S. Servis gibridnogo analiza elektricheskoi aktivnosti mozga i video-trekinga sostoyaniya cheloveka [Human state analysis service: brain electrical activity and video tracking]. *Informatsionnye*

* Received 10 April 2024.

tekhnologii i vychislitel'nye sistemy = *Journal of Information Technologies and Computing Systems*, 2023, no. 4, pp. 72–85. DOI: 10.14357/20718632230407.

3. Li Z., Xiahou X., Chen G., Zhang S., Li Q. EEG-based detection of adverse mental state under multi-dimensional unsafe psychology for construction workers at height. *Developments in the Built Environment*, 2024, vol. 19, p. 100513. DOI: 10.1016/j.dibe.2024.100513.

4. Wang J., Wang Z., Liu G. Recording brain activity while listening to music using wearable EEG devices combined with Bidirectional Long Short-Term Memory Networks. *Alexandria Engineering Journal*, 2024, vol. 109, pp. 1–10. DOI: 10.1016/j.aej.2024.07.122.

5. Sun R., Cheng A.S.K., Chan C., Hsiao J., Privitera A.J., Gao J., Fong C.-h., Ding R., Tang A.C. Tracking gaze position from EEG: Exploring the possibility of an EEG-based virtual eye-tracker. *Brain and Behavior*, 2023, vol. 13 (10). DOI: 10.1002/brb3.3205.

6. Lin C., Zhang C., Xu J., Liu R., Leng Y., Fu C. Neural correlation of EEG and eye movement in natural grasping intention estimation. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2023, vol. 31, pp. 4329–4337.

7. Jia Y., Tyler C. Measurement of saccadic eye movements by electrooculography for simultaneous EEG recording. *Behavior Research Methods*, 2019, vol. 51 (5), pp. 2139–2151. DOI: 10.3758/s13428-019-01280-8.

8. Park S., Han C., Im C. Design of wearable EEG devices specialized for passive brain-computer interface applications. *Sensors (Switzerland)*, 2020, vol. 20 (16), p. 4572. DOI: 10.3390/s20164572.

9. Gosselin F., Navarro-Sune X., Vozzi A., Pandremmenou K., Fallani F.D.V., Attal Y., Chavez M. Quality assessment of single-channel EEG for wearable devices. *Sensors (Switzerland)*, 2019, vol. 19 (3), p. 601. DOI: 10.3390/s19030601.

10. Portillo-Lara R., Tahirbegi B., Chapman C.A.R., Goding J.A., Green R.A. Mind the gap: State-of-the-art technologies and applications for EEG-based brain-computer interfaces. *APL Bioengineering*, 2021, vol. 5 (3), p. 16. DOI: 10.1063/5.0047237.

11. Liao L. de, Chen C.Y., Wang I.J., Chen S.F., Li S.Y., Chen B.W., Chang J.Y., Lin C.T. Gaming control using a wearable and wireless EEG-based brain-computer interface device with novel dry foam-based sensors. *Journal of NeuroEngineering and Rehabilitation*, 2012, vol. 9 (1). DOI: 10.1186/1743-0003-9-5.

12. Gong S., Xing K., Cichocki A., Li J. Deep learning in EEG: Advance of the last ten-year critical period. *IEEE Transactions on Cognitive and Developmental Systems*, 2022, vol. 14 (2), pp. 348–365. DOI: 10.1109/TCDS.2021.3079712.

13. Mehmood I., Li H., Qarout Y., Umer W., Anwer S., Wu H., Hussain M., Fordjour Antwi-Afari M. Deep learning-based construction equipment operators' mental fatigue classification using wearable EEG sensor data. *Advanced Engineering Informatics*, 2023, vol. 56. DOI: 10.1016/j.aei.2023.101978.

14. Zhang G., Davoodnia V., Sepas-Moghaddam A., Zhang Y., Etemad A. Classification of hand movements from EEG using a deep attention-based LSTM network. *IEEE Sensors Journal*, 2019, vol. 20, pp. 3113–3122.

15. Klug M., Gramann K. Identifying key factors for improving ICA-based decomposition of EEG data in mobile and stationary experiments. *European Journal of Neuroscience*, 2021, vol. 54 (12), pp. 8406–8420. DOI: 10.1111/ejn.14992.

16. Butkeviciute E., Bikulciene L., Sidekierskiene T., Blazauskas T., Maskeliunas R., Dama-sevicius R., Wei W. Removal of movement artefact for mobile EEG analysis in sports exercises. *IEEE Access*, 2019, vol. 7, pp. 7206–7217. DOI: 10.1109/ACCESS.2018.2890335.

Для цитирования:

Романюк В.Р. Метод предсказания глазодвигательной активности на основе интеллектуального анализа данных мобильного портативного электроэнцефалографа // Системы анализа и обработки данных. – 2024. – № 3 (95). – С. 77–89. – DOI: 10.17212/2782-2001-2024-3-77-89.

For citation:

Romanyuk V.R. Metod predskazaniya glazodvigatel'noi aktivnosti na osnove intellektual'nogo analiza dannykh mobil'nogo portativnogo elektroentsefalograf [Method for predicting eye movement activity based on intelligent data analysis from a mobile portable electroencephalograph]. *Sistemy analiza i obrabotki dannykh* = *Analysis and Data Processing Systems*, 2024, no. 3 (95), pp. 77–89. DOI: 10.17212/2782-2001-2024-3-77-89.