

<https://doi.org/10.21869/2223-1536-2026-16-2-21-38>

УДК 681.5:004.032.26

Программно-аппаратный комплекс обеспечения функционирования интерфейса типа «мозг-компьютер»

Д. В. Журавлёв¹, А. С. Соловьев², Р. В. Кузьменко^{1,2}, А. В. Калач³✉

¹ Воронежский государственный технический университет
ул. 20-летия Октября, д. 84, г. Воронеж 394006, Российская Федерация

² Воронежский институт Федеральной службы исполнения наказаний России
ул. Иркутская, д. 1А, г. Воронеж 394072, Российская Федерация

³ Воронежский государственный университет инженерных технологий
пр-т Революции, д. 19, г. Воронеж 394036, Российская Федерация

✉ e-mail: a_kalach@mail.ru

Резюме

Целью исследования является разработка программно-аппаратного комплекса, позволяющего оптимизировать управление роботизированным устройством по сигналам электроэнцефалограммы на основе распознавания управляющих команд вне зависимости от принципа взаимодействия пользователя с компьютером.

Методы. Представлен программно-аппаратный комплекс, способный функционировать на основе как синхронной, так и асинхронной парадигм интерфейса «мозг-компьютер», предназначенный для внедрения в различные контуры управления сложными человеко-машинными системами. Аппаратные средства включают в себя плату регистрации сигналов электроэнцефалографии, а также нейроаппаратуру с электродами-датчиками. Плата регистрации сигналов электроэнцефалографии Cyton является ключевым элементом аппаратной части разработанного программно-аппаратного комплекса. Это 8-канальное устройство, совместимое с платформой OpenBCI, предназначенное для высокоточной регистрации биопотенциалов мозга, а также сигналов сердечной и мышечной активности. Разработанное на языке Python программное обеспечение позволяет регистрировать сигналы электроэнцефалографии; предварительной обработки сигналов электроэнцефалографии при реализации синхронного и асинхронного интерфейсов; проводить классификацию данных электроэнцефалографии; формировать управляющие сигналы на роботизированное устройство.

Результаты. Для выполнения задачи классификации данных электроэнцефалографии была разработана модель полносвязной искусственной нейронной сети, представляющей собой многослойный перцептрон (Multi-Layer Perceptron или MLP). В синхронном режиме достигнута точность распознавания потенциала P300 на уровне ~ 60 %. В асинхронном режиме точность бинарной классификации моторных образов (воображаемые движения левой и правой рук) составила 65 %. Разработанный комплекс предусматривает возможность работы системы с операторами без этапа предварительного обучения.

Заключение. Разработанный комплекс открывает перспективы для внедрения интерфейса «мозг-компьютер» в критически важные технологические процессы, где требуется высокая надёжность человеко-машинного взаимодействия. Дальнейшее развитие системы может быть направлено на повышение точности классификации, расширение числа распознаваемых команд и оптимизацию аппаратной части для мобильных применений.

Ключевые слова: асинхронный интерфейс «мозг-компьютер»; волна P300; моторные образы; многослойный перцептрон; человеко-машинный интерфейс.

Конфликт интересов: Авторы декларируют отсутствие явных и потенциальных конфликтов интересов, связанных с публикацией настоящей статьи.

Для цитирования: Программно-аппаратный комплекс обеспечения функционирования интерфейса типа «мозг-компьютер» / Д. В. Журавлёв, А. С. Соловьев, Р. В. Кузьменко, А. В. Калач // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2026. Т. 16, № 2. С. 21–38. <https://doi.org/10.21869/2223-1536-2026-16-2-21-38>.

Поступила в редакцию 17.04.2026

Подписана в печать 15.05.2026

Опубликована 30.06.2026

Hardware and software complex ensuring the functioning of the interface "brain-computer"

Dmitry V. Zhuravlev¹, Alexander S. Soloviev²,
Roman V. Kuzmenko^{1,2}, Andrew V. Kalach³ ✉

¹ Voronezh State Technical University
20-letiya Oktyabrya Str. 84, Voronezh 394006, Russian Federation

² Voronezh Institute of the Federal Penitentiary Service of Russia
1A Irkutskaya Str., Voronezh 394072, Russian Federation

³ Voronezh State University of Engineering Technologies
19 Revolyutsii Ave., Voronezh 394036, Russian Federation

✉ e-mail: a_kalach@mail.ru

Abstract

The purpose of the research is to develop a software and hardware complex that allows optimizing the control of a robotic device based on electroencephalogram signals based on the recognition of control commands, regardless of the principle of user interaction with a computer.

Methods. Presented is a software and hardware complex capable of functioning on the basis of both synchronous and asynchronous paradigms of the "brain-computer" interface, designed for introduction into various control loops of complex human-machine systems. The hardware includes an electroencephalography signal recording board as well as a neuroharnithra with sensor electrodes. The Cyton electroencephalography signal registration board is a key element of the hardware of the developed software and hardware complex. This is an 8-channel device compatible with the OpenBCI platform, designed for high-precision registration of brain biopotentials, as well as signals of heart and muscle activity. Software developed in Python allows you to record electroencephalography signals; pre-processing electroencephalography signals when implementing synchronous and asynchronous interfaces; classify electroencephalography data; generate control signals to the robotic device.

Results. To perform the task of classifying electroencephalography data, a model of a fully connected artificial neural network, which is a multilayer perceptron (Multi-Layer Perceptron or MLP), was developed. In synchronous mode, the P300 has a potential recognition accuracy of ~ 60%. In asynchronous mode, the accuracy of the binary classification of motor images (imaginary movements of the left and right hands) was 65%. The developed complex provides the ability to work with operators without a preliminary training stage.

Conclusion. The developed complex opens up prospects for introducing the brain-computer interface into critical technological processes where high reliability of human-eyelid machine interaction is required. Further development of the system can be aimed at improving classification accuracy, expanding the number of recognizable commands and optimizing the hardware for mobile applications.

Keywords: asynchronous brain-computer interface; wave P300; motor imagery; multilayer perceptron; human-machine interface.

Conflict of interest: The Authors declare the absence of obvious and potential conflicts of interest related to the publication of this article.

For citation: Zhuravlev D.V., Soloviev A.S., Kuzmenko R.V., Kalach A.V. Hardware and software complex ensuring the functioning of the interface "brain-computer". *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Serija: Upravlenie, vychislitel'naja tekhnika, informatika. Meditsinskoe priborostroenie* = *Proceedings of the Southwest State University. Series: Control, Computer Engineering, Information Science. Medical Instruments Engineering*. 2026;16(2):21–38. (In Russ.) <https://doi.org/10.21869/2223-1536-2026-16-2-21-38>.

Received 17.04.2026

Accepted 15.05.2026

Published 30.06.2026

Введение

Современные сложные человеко-машинные системы, особенно в сферах эксплуатации критически важного оборудования, предъявляют высокие требования к надежности, эффективности и безопасности управления. Ключевым элементом таких систем является оператор, чье функциональное состояние напрямую влияет на качество принимаемых решений. Традиционные интерфейсы зачастую не учитывают динамику когнитивной нагрузки и психофизиологического статуса человека, что может привести к ошибкам в условиях повышенной ответственности. В этой связи актуальной задачей становится разработка адаптивных систем, способных в реальном времени интегрировать объективные данные о состоянии оператора в контур управления, формируя биологическую обратную связь и создавая новые каналы для взаимодействия.

Перспективным направлением для создания таких адаптивных систем являются неинвазивные интерфейсы «мозг-компьютер» (ИМК), обеспечивающие прямую связь между человеком и машиной, путем преобразования сигналов мозга в команды управления [1]. Электроэнцефалография (ЭЭГ) является широко используемым методом, применяемым в системах ИМК благодаря своей неинвазивности и высокому временному разрешению. Однако ИМК на основе ЭЭГ часто страдают от низкого

отношения «сигнал/шум» и ограниченного пространственного разрешения, главным образом из-за небольшого количества регистрирующих электродов и их неоптимального расположения [2].

Цель данного исследования – решить эти проблемы, предложив структуру, которая улучшает релевантные для задачи сигналы ЭЭГ с использованием подхода оценки источников, управляемого вниманием, на основе грубо определенных областей мозга

Необходимо отметить, что интерфейсы «мозг-компьютер» обладают потенциалом кардинально изменить нашу жизнь в будущем, взаимодействуя с мозгом как «мост» между нами и внешней средой. Для разработки таких устройств у людей необходимо глубокое понимание механизмов работы мозга. В настоящее время исследования мыслительной способности человека достигли существенного прогресса в выявлении критически важных областей мозга и цепей, имеющих значение для двигательной активности [3].

Интерфейсы «мозг-компьютер» могут быть направлены на обнаружение дисфункциональной мозговой сети и изменение ее функции [4]. Этого можно достичь путем регистрации и стимуляции определенной популяции нейронов с помощью внутричерепной электроэнцефалографии и инвазивной или неинвазивной стимуляции мозга [5]. Учитывая, что мультисенсорный ввод связан с

улучшенным кодированием события, одним из способов улучшения двигательной активности с помощью интерфейса «мозг-компьютер» является стимуляция нейронов в нескольких сенсорных модальностях для передачи семантически согласованной мультисенсорной информации во время кодирования [6].

За последние 50 лет были сделаны первые шаги в разработке интерфейсов «мозг-компьютер», главным образом на животных [7]. Однако для понимания достижений в этой области, особенно в отношении потенциала интерфейсов «мозг-компьютер», необходим тщательный анализ литературы [8]. Существующие решения, как правило, узко специализированы [9] и реализуют либо синхронную парадигму (например, на основе вызванных потенциалов P300) [10], требующую внешней стимуляции, либо асинхронную (на основе воображаемых движений) [11], позволяющую оператору инициировать команды произвольно [12]. Каждый тип имеет свои преимущества и ограничения [13], а их жесткое разделение сужает потенциальную область применения ИМК [14]. Создание универсальной платформы, способной гибко работать в обоих режимах [15], представляет собой комплексную научно-техническую проблему. Её решение требует применения методов системного анализа для интеграции аппаратных и программных компонентов, разработки алгоритмов обработки многомерной и нестационарной нейрофизиологической информации [16], а также создания адаптивных классификаторов, устойчивых к индивидуальным особенностям операторов.

Исследование посвящено разработке и апробации именно такого универсального программно-аппаратного комплекса. Основная идея заключается в реализации единой архитектуры нейроклассификатора на основе многослойного персептрона, которая в сочетании с соответствующими методами предварительной обработки эффективно классифицирует как сигналы с волной P300, так и паттерны с воображаемыми моторными образами.

Цель работы – создать гибкий инструмент, позволяющий в зависимости от решаемой задачи и условий эксплуатации выбирать оптимальный режим работы ИМК, тем самым повышая надежность и эффективность управления сложными технологическими процессами за счет прямого учета состояния человека-оператора.

Материалы и методы

Можно выделить основные этапы работы разработанного программно-аппаратного комплекса (ПАК): регистрация сигналов электроэнцефалограммы (ЭЭГ), предварительная обработка данных, формирование входных векторов из данных, содержащих выделенные признаки, классификация данных [17]. Для того чтобы получить данные ЭЭГ, содержащие классифицируемые признаки, проводят сеансы записи биопотенциалов, используя аппаратные средства, включающие электроды-датчики, а также устройства сбора и хранения данных ЭЭГ. Примерами таких устройств могут выступать как профессиональное оборудование, используемое в различных профильных медицинских центрах, так и портативные платы регистрации, доступные ши-

рокому кругу пользователей, такие как плата Cyton от проекта OpenBCI. Предварительная обработка сигналов ЭЭГ заключается в устранении шумов и артефактов, возникших в ходе регистрации биопотенциалов, а также применении методов системного анализа для выделения полезных признаков из непрерывного сигнала ЭЭГ. В этой связи на данном этапе также проводится фильтрация сигналов ЭЭГ в заданном частотном диапазоне. Отметим, что в ходе предварительной обработки сигналов ЭЭГ осуществляется дискретное преобразование аналоговых сигналов ЭЭГ. Широкое применение на этапе предобработки нашел метод общего пространственного паттерна (Common Spatial Pattern или CSP) [18]. Извлечение признаков включает преобразование сырого сигнала эпохи в компактный набор числовых характеристик (признаков), которые наиболее информативны для различия классов (например, «целевой стимул» и «нецелевой» или «воображение движения левой / правой руки»). В современных исследованиях для классификации сигналов ЭЭГ применяют методы машинного и глубокого обучения [19]. Эти алгоритмы предназначены для анализа извлечённых признаков (в нашем случае в зависимости от режима работы – это волна P300 или моторные образы лево / право). Бинарные классификаторы для режима онлайн обычно строятся на основе таких нересурсозатратных математических моделей, как линейный дискриминантный анализ (LDA) или метод опорных векторов (SVM). Также применяются нейросетевые модели (в частности, многослойный персептрон или MLP) [20].

Основные различия между синхронными и асинхронными интерфейсами «мозг-компьютер» заключаются в принципах взаимодействия с пользователем, способах обработки сигналов и архитектурных требованиях к системе.

Синхронные интерфейсы функционируют в строгом соответствии с внешними стимулами, предъявляемыми пользователю в определённые моменты времени: визуальными, звуковыми или тактильными. Пользователь концентрируется на целевом стимуле, что вызывает в его мозговой активности характерные паттерны, такие как волна P300. Система анализирует ЭЭГ в привязке к моментам стимуляции и выделяет эти отклики для интерпретации команд. Такой подход обеспечивает высокую степень предсказуемости сигнала, что упрощает его обработку и повышает надёжность классификации. Однако он требует жёсткой синхронизации между человеком и устройством, а также длительного обучения оператора для достижения стабильных результатов.

Асинхронные интерфейсы, напротив, не привязаны к внешним триггерам и непрерывно анализируют мозговую активность в режиме реального времени. Пользователь может формировать управляющие команды в произвольный момент, например, представляя движение левой или правой руки [21]. Необходимо отметить, что система должна распознать эти моторные образы среди фоновой активности, что требует более сложных алгоритмов обработки, мощных вычислительных ресурсов и устойчивых моделей классификации [22]. Преимуществом асинхронных ИМК является их естественность и гибкость,

позволяющая более свободное и интуитивное управление [23].

Важно отметить, что асинхронные системы традиционно требуют длительной тренировки пользователя, однако в представленном исследовании достигнута работоспособность без предварительной адаптации, что является существенным достижением. Таким образом, выбор между синхронным и асинхронным режимом определяется конкретной задачей: синхронные интерфейсы предпочтительны в условиях контролируемого взаимодействия, а асинхронные – при необходимости спонтанного и непрерывного управления внешними устройствами.

В рамках описанного в настоящей работе исследования был разработан ПАК для управления роботизированным устройством по сигналам ЭЭГ на основе распознавания управляющих команд.

Аппаратные средства включают в себя плату регистрации сигналов ЭЭГ, а также нейрогарнитуру с электродами-датчиками. Плата регистрации сигналов ЭЭГ Cyton является ключевым элементом аппаратной части разработанного программно-аппаратного комплекса. Это 8-канальное устройство, совместимое с платформой OpenBCI, предназначенное для высокоточной регистрации биопотенциалов мозга (ЭЭГ), а также сигналов сердечной (ЭКГ) и мышечной (ЭМГ) активности. Отметим, что Cyton имеет возможность осуществлять 16-канальную регистрацию сигналов ЭЭГ с использованием платы увеличения каналов Daisy. Внешний вид модернизированной платы регистрации для 8-канального исполнения, сочетающей в себе модуль реги-

страции и модуль передачи сигналов по радиоканалу стандарта Wi-Fi, представлен в работе [24]. Плата основана на 24-битном аналого-цифровом преобразователе ADS1299, обеспечивающем высокое разрешение и низкий уровень шума, что критически важно для обработки низковольтных биопотенциалов. Каждый канал имеет независимый усилитель биопотенциалов с программируемым коэффициентом усиления и фильтрацией, что позволяет эффективно подавлять помехи и синфазные сигналы. Плата Cyton оснащена микроконтроллером PIC32MX250F128B, обеспечивающим быструю обработку данных, и поддерживает беспроводную передачу информации по Wi-Fi или Bluetooth через дополнительные модули. Частота дискретизации составляет до 250 Гц на канал, что достаточно для анализа широкого спектра паттернов ЭЭГ. Плата совместима с нейрогарнитурами, включая Ultracortex Mark IV, и поддерживает работу как с электродами «мокрого», так и «сухого» типов, а открытая архитектура и поддержка программного обеспечения (ПО) с открытым исходным кодом делают Cyton удобной платформой для исследований в области ИМК для человеко-машинных интерфейсов.

В настоящем исследовании для непосредственной регистрации сигналов ЭЭГ использовались электроды «сухого» типа, которые для удобства располагались в соответствующих отверстиях распечатанной на 3D-принтере нейрогарнитуры. Расположение электродов осуществлялось в отведениях, соответствующих международной системе «10-20» [24].

Разработанное на языке Python ПО, включает в себя следующие программные модули:

- модуль регистрации сигналов ЭЭГ;
- модуль предварительной обработки сигналов ЭЭГ при реализации синхронного ИМК;
- модуль предварительной обработки сигналов ЭЭГ при реализации асинхронного ИМК;
- модуль для проведения классификации данных ЭЭГ;
- модуль для формирования управляющих сигналов на роботизированное устройство;
- модуль для предъявления зрительных стимулов;
- модуль для взаимодействия пульта управления роботизированным устройством и остальными программными модулями.

Для выполнения задачи классификации данных ЭЭГ была разработана модель полносвязной искусственной нейронной сети (ИНС), представляющей собой многослойный персептрон (Multi-Layer Perceptron или MLP). Для разработки единой методики предварительной обработки сигналов ЭЭГ необходимо собрать большую базу данных ЭЭГ сигналов с участием разных испытуемых, формируя таким образом дикторонезависимый набор данных (под дикторонезависимым понимается набор данных, полученный на различных операторах без их предварительной подготовки). Следует также отметить, что технология применения электродов «сухого» типа является новой, в связи с чем при использовании разработанной аппаратуры для снятия сигналов ЭЭГ зачастую возникали артефакты во время

регистрации. Поэтому для получения больших дикторонезависимых наборов данных с использованием профессионального лабораторного оборудования, основанного на технологии электродов «мокрого» типа, нами была взята база данных ЭЭГ от центра биомедицинской визуализации Атинулы А. Мартиноса. Данная база ЭЭГ сигналов собрана с применением оборудования Neuromag Vectorview с использованием 60-ти отведений для локализации электродов «мокрого» типа. В ходе испытаний пациентам через каждые 750 мс предъявляли различные стимулы.

Поскольку использование данных со всех 60-ти каналов ЭЭГ в задаче классификации требует больших вычислительных мощностей, весьма целесообразно сократить количество используемых каналов до 8-ми. Такое число каналов обусловлено тем, что для проверки работоспособности ИМК в асинхронном режиме нами была использована база записей, сформированная с использованием разработанного ПАК. Такая база содержала более 300 образцов записей, сформированных на отдельных операторах в различное время. Все записи были сделаны на ИМК, имеющем 8-канальное исполнение, и содержали по 20 паттернов воображаемых моторных образов движений левой / правой рук оператора.

Сокращение числа каналов до 8-позиции позволило провести обучение искусственной нейронной сети (ИНС) на пользовательском ПК. Предварительная обработка сигналов ЭЭГ заключалась в удалении артефактов записи, а затем непрерывный сигнал ЭЭГ был разделён на сегменты (эпохи), содержащие волну P300 и не содержащие волну P300 для

случая синхронного ИМК. Каждый такой сегмент образовывался за 0,5 с до предъявления стимула и 1 с после предъявления стимула. Далее, были созданы массивы с данными, содержащими сегменты с P300, и с данными, не содержащими P300. В массиве имеется 12 строк, соответствующих 12-ти событиям с волной P300, а также 8 столбцов, соответствующих эпохам с каждого из 8 каналов регистрации ЭЭГ-сигналов. Данные, не содержащие P300, соответствуют событиям № 1, 2, 3, 4, 32. Общее количество таких эпох составило 208. Таким образом, массив с эпохами, не содержащими P300, аналогичен представленному выше, но имеет 208 строк и 8 столбцов.

Далее были созданы два вектора для данных, содержащих P300, и для данных, не содержащих P300. Для этой эпохи, содержащей волну P300 для каждого из 8-ми каналов, записывались в ячейки одной строки массива. Размерность данного массива составляла 12 строк и 1808 столбцов. Строки соответствовали числу событий. Столбцы соответствовали числу отсчетов каждой эпохи для каждого из 8-ми каналов. Таким образом, экспериментально установлено, что одна эпоха содержит $1808 / 8 = 226$ дискретных отсчетов сигнала.

Отметим, что аналогичные операции выполняли и для массива с эпохами, не содержащими волну P300. Затем каждый массив подвергали транспонированию (осуществляли замену строк столбцами) и нормализации данных с помощью встроенной функции пакета Python RobustScaler. После выполнения нормализации к обоим массивам применялось обратное транспонирование.

В конечном итоге данные были разделены на обучающие и тестовые наборы.

Для классификации данных была разработана модель полносвязной ИНС с использованием библиотеки `tensorflow.keras`. Учитывая представленные выше данные, для проведения классификации нам требуется модель ИНС, содержащая в составе входного слоя 1808 искусственных нейронов. Оптимальное количество скрытых слоев устанавливается экспериментальным методом подбора. В настоящем исследовании наилучших результатов удалось достичь при использовании модели ИНС с двумя скрытыми слоями по 128 нейронов в каждом. Функция активации нейронов скрытого слоя – линейная ректификация (ReLU), задаваемая следующим выражением:

$$\text{ReLU}(x) = \max(0, x), \quad (1)$$

где x – входное значение нейрона; $\max(\cdot)$ – функция, которая возвращает максимальное значение из 2-х возможных значений 0 и x (если $x > 0$, то функция возвращает значение x , и функция возвращает значение 0, если $x \leq 0$).

В качестве функции ошибки применялась бинарная кросс-энтропия (Binary Cross Entropy или *BCE*). Математически данная функция задается с помощью выражения

$$BCE = -\frac{1}{N} \sum_{i=1}^N [d_i \log y_i + (1 - d_i) \log(1 - y_i)], \quad (2)$$

где N – количество наблюдений; d_i – бинарная метка (0 или 1) для i -го наблюдения; y_i – предсказанная вероятность того, что наблюдение i принадлежит к определенному классу.

Отметим, что выходные значения для функции *BCE* представляют собой

распределение вероятностных числовых значений, лежащих в диапазоне $[0-1]$. В процессе обучения необходима корректировка весовых значений ИНС. Для задачи оптимизации процесса обучения модели ИНС использовался алгоритм адаптивной оценки момента (Adaptive Momentum), более известный как ADAM [25], основанный на традиционном алгоритме стохастического градиентного спуска.

Для предотвращения эффекта переобучения модели MLP в настоящей работе применялся алгоритм Dropout, который представляет собой метод регуляризации в машинном обучении. Данный подход подразумевает отключение части случайным образом выбранных нейронов в ходе обучения модели ИНС.

В алгоритме Dropout каждый нейрон слоя с вероятностью P «выключается» (его выход обнуляется), а с вероятностью $q=1-p$ остаётся активным. Математическое представление алгоритма для i -го нейрона слоя:

$$U_i = \Theta_i \cdot a \left(\sum_{k=1}^H \varpi_k x_k + b \right), \quad (3)$$

где U_i – выходной сигнал нейрона; Θ_i – случайная бинарная переменная Бернулли: $P(\Theta_i = 0) = p$, $P(\Theta_i = 1) = q = 1 - p$; $a(\cdot)$ – функция активации; H – число нейронов в предыдущем слое; ϖ_k – веса связей нейронов; x_k – входные сигналы; b – смещение.

Далее проведем расчёт среднего числа оставшихся нейронов в алгоритме Dropout. Обозначим через n общее число нейронов в рассматриваемом слое. При этом X_i – случайная величина (индикатор состояния i -го нейрона),

будет принимать следующие значения: 1, если нейрон активен, и 0, если выключен. Тогда вероятность выключения нейрона будет $P(X_i = 0) = p$, а вероятность сохранения нейрона будет $P(X_i = 1) = q = 1 - p$.

Обозначим через Y число оставшихся (активных) нейронов в слое после применения Dropout, тогда:

$$Y = \sum_{i=1}^n X_i Z. \quad (4)$$

Сумма Y имеет биномиальное распределение: $Y \approx \text{Binomial}(n, q)$, поэтому среднее число активных нейронов (математическое ожидание) будет равно

$$E[Y] = n \cdot q = n \cdot (1 - p). \quad (5)$$

Таким образом, после применения алгоритма Dropout в слое останется $n \cdot (1 - p)$ нейронов, при этом дисперсия биномиальной случайной величины (числа активных нейронов) равна

$$\text{Var}(Y) = n \cdot q \cdot p = n \cdot (1 - p) p. \quad (6)$$

Теперь проведем расчёт среднего числа отключенных нейронов после применения алгоритма Dropout. Обозначим через Z число отключённых нейронов в слое после применения Dropout:

$$Z = \sum_{i=1}^n X_i. \quad (7)$$

Для биномиального распределения математическое ожидание вычисляли следующим образом:

$$E[Z] = n \cdot p. \quad (8)$$

Таким образом, в среднем при применении Dropout будет отключено $n \cdot p$

нейронов, при этом дисперсия биномиальной случайной величины равна

$$\text{Var}(Z) = n \cdot p \cdot (1 - p) = n \cdot p \cdot q. \quad (9)$$

Следует отметить, что стандартным значением вероятности отключения нейрона принимают $P = 0,5$. Однако точное значение вероятности P вычисляется экспериментальным путем. Оптимальных значений классификации удалось достичь при значении $P = 0,3$. В результате применение алгоритма регуляризации Dropout приводит к минимальным искажениям выходного сигнала

ла используемой в настоящей работе модели MLP. Предварительная обработка сигнала для варианта асинхронного ИМК при классификации моторных образов «лево / право» проводилась аналогично.

Результаты и их обсуждение

Полученные в результате экспериментов средние точности классификации для синхронного и асинхронного режимов работы ПАК приведены ниже (табл. 1).

Таблица 1. Средние точности классификации

Table 1. Average classification accuracy

Режим работы ПАК	Средняя точность классификации, %
Синхронный	60,98
Асинхронный	65,92

Рассмотрим графики распределения средних точностей классификации для синхронного и асинхронного режимов

работы ИМК на протяжении 50-эпох обучения (рис. 1).




Рис. 1. Средняя точность классификации для синхронного и асинхронного режимов работы ИМК, %

Fig. 1. Average classification accuracy for synchronous and asynchronous modes of IMC operation, %

Установлено, что ошибка разработанной модели полносвязной нейронной сети для обучающего и тестового множества данных достигает минимальных значений уже к 10-й эпохе. На этапе тестирования функция ошибки достигает своего минимума к 25-й эпохе, что является хорошим результатом обобщения данных искусственной нейронной сетью при общем количестве эпох обучения, равном 50-ти.

Рассмотренный выше алгоритм Dropout успешно предотвращает переобучение нейронной сети. Для тестирования и практического применения в режиме онлайн разработанного ПАК использовался собственный набор данных ЭЭГ (моторные образы «лево / право»), полученный с помощью аппаратуры регистрации, описанной ранее.

Разработанный ПАК предоставляет оператору возможность самостоятельно выбирать режимы функционирования ИМК. Для работы в режиме синхронного ИМК оператору понадобится виртуальный пульт управления роботом. В режиме синхронного ИМК оператору предстоит мысленно сконцентрироваться на конкретной кнопке пульта управления роботизированного устройства. Головной мозг сформирует волну P300, которая является откликом на подсвечивание выбранной кнопки. Если по результатам бинарной классификации отклик P300 соответствует подсвеченной в настоящий момент кнопке с вероятностью не менее 60 %, ПО автоматически формирует управляющий сигнал для робототехнического устройства. При этом сигнал соответствует привязанно-

му к данной кнопке действию. Управляющие сигналы формируются с использованием интерфейса прикладного программирования (API).

В режиме асинхронного ИМК оператору представляется возможность использовать моторные образы для формирования управляющих команд. Оператор мысленно представляет движения левой или правой руки, а система в ответ формирует одну из 2-х возможных управляющих команд. Отдельно следует отметить, что для работы в режиме асинхронного ИМК оператору не требуется виртуальный пульт управления.

Практическое апробирование разработанного ПАК осуществляли на собственном наборе данных, полученных с использованием ранее описанной регистрирующей аппаратуры и сторонней базы записей. По результатам классификации как в синхронном, так и в асинхронном режимах системой формировались управляющие команды, с помощью которых и осуществлялось управление роботизированным устройством.

Тестирование разработанного ПАК в качестве асинхронного ИМК осуществлялось в режиме онлайн с использованием собственной базы данных ЭЭГ. В данном режиме оператор мысленно представлял движение левой или правой рукой, а система классифицировала моторные образы. Отметим, что точность классификации моторных образов в среднем составила более 65%. В результате успешной классификации и распознавания моторных образов система формировала управляющие команды и осуществляла управление роботом.

Предложенная универсальная методика предварительной обработки ЭЭГ-сигналов применима как для синхронного (P300), так и для асинхронного (моторные образы) варианта ИМК в режимах онлайн и офлайн. Её цель – извлечь информативные, устойчивые к шуму пространственно-временные признаки.

Рассмотрим основные этапы методики.

1. Полосовая фильтрация. Исходный непрерывный сигнал фильтруется для выделения физиологически релевантной полосы частот.

2. Сегментация. Для анализа сигнал разбивается на перекрывающиеся эпохи (окна). Используются сегменты длительностью ~ 4 с с шагом смещения 0,5 с. Это обеспечивает баланс между захватом достаточного количества информации для анализа и поддержанием временного разрешения, необходимого для онлайн-работы.

3. Пространственная фильтрация (CSP). К каждому сегменту применяется метод CSP. Этот этап критически важен для выделения паттернов, ассоциированных с различными ментальными состояниями (например, воображением движений разных рук) или реакцией на стимул (P300). CSP-фильтр максимизирует дисперсию сигнала для одного класса при одновременной минимизации дисперсии для другого, эффективно проецируя многоканальные данные в пространство с лучшей разделимостью классов.

4. Формирование объединённого вектора данных. После пространственной

фильтрации данные для анализа объединяются в единый вектор для последующего детального временного анализа.

5. Детальная временная сегментация и нелинейное преобразование. Объединённый вектор вновь сегментируется на короткие перекрывающиеся окна (длиной ~ 1 с с шагом 0,0625 с). К каждому такому короткому сегменту применяется операция возведения каждого отсчета в квадрат. Данное нелинейное преобразование подчеркивает энергетические характеристики сигнала и позволяет усиливать слабые, но информативные компоненты (такие как P300), одновременно подавляя нормальное распределение шума.

6. Логарифмическое преобразование и нормализация. К результату предыдущего шага применяли операцию логарифмирования, что служит двум целям: стабилизация дисперсии (сжатие динамического диапазона) и приближение распределения признаков к нормальному, что часто повышает эффективность последующих линейных классификаторов.

После проведения предварительной обработки формируется итоговый вектор признаков. Все обработанные короткие сегменты объединяются в единый многомерный вектор признаков. Этот вектор содержит сжатое, но информативное описание пространственно-временной и энергетической структуры исходного ЭЭГ-сегмента.

Далее формируется слой загрузки данных даталоадер (DataLoader) и данные подаются на вход бинарного классификатора (например, многослойного

персептрона, как в нашем случае), который принимает решение о принадлежности сегмента к тому или иному классу.

Выводы

В ходе выполнения исследования был разработан и апробирован универсальный ПАК для управления роботизированными устройствами посредством ИМК двух типов: синхронного и асинхронного. Ключевым достижением стала единая архитектура классификатора на основе многослойного персептрона, способная эффективно обрабатывать разнородные сигналы головного мозга человека-оператора:

- волны Р300 в синхронном режиме (точность распознавания – 60 % в режиме «онлайн»);

- моторные образы (воображаемые движения левой и правой руками) в асинхронном режиме (точность классификации – 65 % в режиме «онлайн»).

Важными практическими результатами разработанного ПАК являются:

- отсутствие необходимости в предварительной тренировке операторов, что подтверждает адаптивность системы к индивидуальным особенностям нейрофизиологических сигналов;

- апробированная методика предварительной обработки ЭЭГ, обеспечивающая устойчивость классификации в условиях реального времени;

- доказанная работоспособность комплекса с обоими типами ИМК, что расширяет сферу его применения при эксплуатации критически важного технологического оборудования;

- реализован комплексный подход к интеграции разработанного ПАК в контуры управления сложных человеко-машинных систем;

- разработаны алгоритмы обработки многомерных временных рядов ЭЭГ;

- продемонстрирована возможность адаптивного принятия решений на основе мониторинга функционального состояния оператора.

Разработанный комплекс открывает перспективы для внедрения ИМК в критически важные технологические процессы, где требуется высокая надёжность человеко-машинного взаимодействия. Дальнейшее развитие системы может быть направлено на повышение точности классификации, расширение числа распознаваемых команд и оптимизацию аппаратной части для мобильных применений.

Список литературы

1. Allison B. Z., Pineda J. A. ERPs evoked by different matrix sizes: implications for a brain computer interface (BCI) system // IEEE Trans. Neural Syst. Rehabil. Eng. 2003. N 11(2). P. 110–113.
2. Filter bank common spatial pattern (FBCSP) in brain-computer interface / K. K. Ang, Z. Y. Chin, H. Zhang, C. Guan // 2008 IEEE International Joint Conference on Neural Networks. Hong Kong: IEEE, 2008. P. 2390–2397. <https://doi.org/10.1109/IJCNN.2008.4634130>.

3. A human memory circuit derived from brain lesions causing amnesia / M. A. Ferguson, C. Lim, D. Cooke [et al.] // *Nat. Commun.* 2019. N 10 (1). P. 3497. <https://doi.org/10.1038/s41467-019-11353-z>.
4. Parvizi J., Kastner S. Promises and limitations of human intracranial electroencephalography // *Nat. Neurosci.* 2018. N 21(4). P. 474–483. <https://doi.org/10.1038/s41593-018-0108-2>.
5. Targeted enhancement of cortical-hippocampal brain networks and associative memory / J. X. Wang, L. M. Rogers, E. Z. Gross [et al.] // *Science*. 2014. N 345 (6200). P. 1054–1057. <https://doi.org/10.1126/science.1252900>.
6. Multisensory processing impacts memory for objects and their sources / S. E. Duarte, A. P. Yonelinas, S. Ghetti [et al.] // *Mem. Cognit.* 2024. N 53 (2). P. 646–665. <https://doi.org/10.3758/s13421-024-01592-x>.
7. Learning to control a brain-machine interface for reaching and grasping by primates / J. M. Carmena, M. A. Lebedev, R. E. Crist [et al.] // *PLoS Biol.* 2003. N 1 (2). P. e42.
8. Musk E. An integrated brain-machine interface platform with thousands of channels // *J. Med. Internet. Res.* 2019. N 21 (10). P. e16194. <https://doi.org/10.2196/16194>.
9. Vidal J. J. Toward direct brain-computer communication // *Annu. Rev. Biophys. Bioeng.* 1973. N 2 (1). P. 157–180. <https://doi.org/10.1146/annurev.bb.02.060173.001105>.
10. Scientific profile of brain-computer interfaces: bibliometric analysis in a 10-year period / K. Hu, C. Chen, Q. Meng [et al.] // *Neurosci. Lett.* 2016. N 635. P. 61–66. <https://doi.org/10.1016/j.neulet.2016.10.022>.
11. A Bibliometric analysis of the application of brain-computer interface in rehabilitation medicine over the past 20 years / J. Huang, L. Huang, Y. Li [et al.] // *J. Multidiscip. Healthc.* 2025. N 18. P. 1297–1317. <https://doi.org/10.2147/JMDH.S509747>.
12. EEG-inception: a novel deep convolutional neural network for assistive ERP-based brain-computer interfaces / E. Santamaria-Vazquez, V. Martinez-Cagigal, F. Vaquerizo-Villar [et al.] // *IEEE Trans. Neural Syst. Rehabil. Eng.* 2020. N 28 (12). P. 2773–2782.
13. Kapsetaki M. E. Scientometric analysis of Greek publications on stereotactic and functional neurosurgery // *Next Res.* 2025. N 2 (3). P. 100531. <https://doi.org/10.1016/j.nexres.2025.100531>.
14. Bibliometric analysis on brain-computer interfaces in a 30-year period / Z. Yin, Y. Wan, H. Fang [et al.] // *Appl. Intell.* 2023. N 53 (12). P. 16205–16225.
15. Sakhavi S., Guan C., Yan S. Learning temporal information for brain-computer interface using convolutional neural networks // *IEEE Trans. Neural Netw. Learn. Syst.* 2018. N 29 (11). P. 5619–5629.
16. Kapsetaki M. E. Brain-computer interfaces for memory enhancement: Scientometric analysis and future directions // *Biomedical Signal Processing and Control*. 2026. Vol. 112, pt. D. P. 108904. <https://doi.org/10.1016/j.bspc.2025.108904>.
17. Neurofeedback & P300 toolbox for neurorehabilitation: measurement and analysis of brain activity, network and cognitive decline-related P300 / E. Lee, Y. Kang, H. Kim, J. Lee // *Biomedical Physics & Engineering Express*. 2025. Vol. 11, N 6. P. 65004. <https://doi.org/10.1088/2057-1976/ae0ad7>.

18. Significance of EEG-electrode combinations while calculating filters with common spatial patterns / D. Wetzel, P.-P. Jacobs, D. Winkler, R. Grunert // *Ger. Med. Sci.* 2024. Vol. 22. <https://doi.org/10.3205/000334>.
19. Review of EEG signal classification / A. R. Chakole [et al.] // *Information and Communication Technology for Intelligent Systems: Proceedings of ICTIS 2018*. Singapore: Springer, 2019. Vol. 2. P. 105–114. https://doi.org/10.1007/978-981-13-1747-7_11.
20. Сравнительный анализ особенностей архитектур систем поддержки принятия решений для адаптации образовательных программ: от RuBERT до онтологически-графовых моделей / А. В. Калач, И. С. Кожевников, А. С. Кравченко [и др.] // *Моделирование систем и процессов*. 2025. Т. 18, № 3. С. 62–70. <https://doi.org/10.12737/2219-0767-2025-18-3-62-70>. EDN ESUQJE.
21. Feature Extraction and Classification of Motor Imagery EEG Signals in Motor Imagery for Sustainable Brain – Computer Interfaces / Y. Lu, W. Wang, B. Lian, C. He // *Sustainability*. 2024. Vol. 16. P. 6627. <https://doi.org/10.3390/su16156627>.
22. Nambiar A., Sivakumar R., Subramaniam S. Detection of Four Class Motor Imagery from EEG Signal for Brain-Computer Interface Applications // *Applied Mathematics, Modeling and Computer Simulation*. 2023. <https://doi.org/10.3233/ATDE231028>.
23. Станкевич Л. А., Журавская А. Управление мобильным роботом на основе нейроинтерфейса // *Экстремальная робототехника*. 2022. № 1 (33). С. 348–354. EDN: RWPBSY.
24. Журавлев Д. В., Голубинский А. Н., Резниченко А. А. Универсальный программно-аппаратный комплекс для управления роботизированными устройствами на основе принципов работы синхронного или асинхронного интерфейсов «мозг-компьютер» // *Журнал радиоэлектроники*. 2025. № 1. С. 9. <https://doi.org/10.30898/1684-1719.2025.1.1>.
25. Kingma D. P. Adam: A method for stochastic optimization // *archive.org*. URL: <https://archive.org/details/arxiv-1412.6980> (дата обращения: 10.03.2026).

References

1. Allison B.Z., Pineda J.A. ERPs evoked by different matrix sizes: implications for a brain computer interface (BCI) system. *IEEE Trans. Neural Syst. Rehabil. Eng.* 2003;(11):110–113.
2. Ang K.K., Chin Z.Y., Zhang H., Guan C. Filter bank common spatial pattern (FBCSP) in brain-computer interface. *IEEE International Joint Conference on Neural Networks*. Hong Kong; IEEE; 2008. P. 2390–2397. <https://doi.org/10.1109/IJCNN.2008.4634130>.
3. Ferguson M.A., Lim C., Cooke D., et al. A human memory circuit derived from brain lesions causing amnesia. *Nat. Commun.* 2019;(10):3497. <https://doi.org/10.1038/s41467-019-11353-z>.
4. Parvizi J., Kastner S. Promises and limitations of human intracranial electroencephalography. *Nat. Neurosci.* 2018;(21):474-483. <https://doi.org/10.1038/s41593-018-0108-2>.

5. Wang J.X., Rogers L.M., Gross E.Z., et al. Targeted enhancement of cortical-hippocampal brain networks and associative memory. *Science*. 2014;(345):1054-1057. <https://doi.org/10.1126/science.1252900>.
6. Duarte S.E., Yonelinas A.P., Gheiti S., et al. Multisensory processing impacts memory for objects and their sources. *Mem. Cognit.* 2024;(53):646-665. <https://doi.org/10.3758/s13421-024-01592-x>.
7. Carmena J.M., Lebedev M.A., Crist R.E., et al. Learning to control a brain-machine interface for reaching and grasping by primates. *PLoS Biol.* 2003;(1):e42.
8. Musk E. An integrated brain-machine interface platform with thousands of channels. *J. Med. Internet. Res.* 2019;(21):e16194. <https://doi.org/10.2196/16194>.
9. Vidal J.J. Toward direct brain-computer communication. *Annu. Rev. Biophys. Bioeng.* 1973;(2):157-180. <https://doi.org/10.1146/annurev.bb.02.060173.001105>.
10. Hu K., Chen C., Meng Q., et al. Scientific profile of brain-computer interfaces: bibliometric analysis in a 10-year period. *Neurosci. Lett.* 2016;(635):61-66. <https://doi.org/10.1016/j.neulet.2016.10.022>.
11. Huang J., Huang L., Li Y., et al. A Bibliometric analysis of the application of brain-computer interface in rehabilitation medicine over the past 20 years. *J. Multidiscip. Healthc.* 2025;(18):1297-1317. <https://doi.org/10.2147/JMDH.S509747>.
12. Santamaria-Vazquez E., Martinez-Cagigal V., Vaquerizo-Villar F., et al. EEG-inception: a novel deep convolutional neural network for assistive ERP-based brain-computer interfaces. *IEEE Trans. Neural Syst. Rehabil. Eng.* 2020;(28):2773-2782.
13. Kapsetaki M.E. Scientometric analysis of Greek publications on stereotactic and functional neurosurgery. *Next Res.* 2025;(2):e 100531. <https://doi.org/10.1016/j.nexres.2025.100531>.
14. Yin Z., Wan Y., Fang H., et al. Bibliometric analysis on brain-computer interfaces in a 30-year period. *Appl. Intell.* 2023;(53):16205-16225.
15. Sakhavi S., Guan C., Yan S. Learning temporal information for brain-computer interface using convolutional neural networks. *IEEE Trans. Neural Netw. Learn. Syst.* 2018;(29):5619-5629.
16. Kapsetaki M.E. Brain-computer interfaces for memory enhancement: Scientometric analysis and future directions. *Biomedical Signal Processing and Control.* 2026;112:108904. <https://doi.org/10.1016/j.bspc.2025.108904>.
17. Lee E., Kang Y., Kim H., Lee J. Neurofeedback & P300 toolbox for neurorehabilitation: measurement and analysis of brain activity, network and cognitive decline-related P300. *Biomedical Physics & Engineering Express.* 2025;11(6):65004. <https://doi.org/10.1088/2057-1976/ae0ad7>.
18. Wetzel D., Jacobs P.-P., Winkler D., Grunert R. Significance of EEG-electrode combinations while calculating filters with common spatial patterns. *Ger. Med. Sci.* 2024;22. <https://doi.org/10.3205/000334>.
19. Chakole A.R., et al. Review of EEG signal classification. *Information and Communication Technology for Intelligent Systems: Proceedings of ICTIS 2018*. Vol. 2. Singapore: Springer; 2019. P. 105–114. https://doi.org/10.1007/978-981-13-1747-7_11.

20. Kalach A.V., Kozhevnikov I.S., Kravchenko A.S., et al. Comparative analysis of the features of the architectures of decision support systems for adapting educational programs: from RuBERT to ontological graph models. *Modelirovanie sistem i processov = Modeling Systems and Processes*. 2025;18(3):62-70. (In Russ.) <https://doi.org/10.12737/2219-0767-2025-18-3-62-70>. EDN ESUQJE.

21. Lu Y., Wang W., Lian B., He C. Feature Extraction and Classification of Motor Imagery EEG Signals in Motor Imagery for Sustainable Brain – Computer Interfaces. *Sustainability*. 2024;16:6627. <https://doi.org/10.3390/su16156627>.

22. Nambiar A., Sivakumar R., Subramaniam S. Detection of Four Class Motor Imagery from EEG Signal for Brain-Computer Interface Applications. *Applied Mathematics, Modeling and Computer Simulation*. 2023. <https://doi.org/10.3233/ATDE231028>.

23. Stankevich L.A., Zhuravskaya A. Control of a mobile robot based on a neurointerface. *Ekstremal'naya robototekhnika = Extreme Robotics*. 2022;(1):348-354. (In Russ.) EDN: RWPBSY.

24. Zhuravlev D.V., Golubinsky A.N., Reznichenko A.A. Universal software and hardware complex for controlling robotic devices based on the principles of operation of synchronous or asynchronous brain-computer interfaces. *Zhurnal radioelektroniki = Journal of Radio Electronics*. 2025;(1):9. <https://doi.org/https://doi.org/10.30898/1684-1719.2025.1.1>. (In Russ.)

25. Kingma D.P. Adam: A method for stochastic optimization. Available at: <https://archive.org/details/arxiv-1412.6980> (accessed 10.03.2026).

Информация об авторах / Information about the Authors

Журавлёв Дмитрий Владимирович,
кандидат технических наук, доцент,
заведующий кафедрой радиоэлектронных
устройств и систем, Воронежский
государственный технический университет,
г. Воронеж, Российская Федерация,
e-mail: ddom1@yandex.ru,
ORCID: 0000-0002-1087-9704

Dmitry V. Zhuravlev, Cand. Sci. (Engineering),
Associate Professor, Head of the Department
of Radioelectronic Devices and Systems,
Voronezh State Technical University,
Voronezh, Russian Federation,
e-mail: ddom1@yandex.ru,
ORCID: 0000-0002-1087-9704

Соловьев Александр Семенович,
доктор технических наук, профессор,
Воронежский институт Федеральной
службы исполнения наказаний России,
г. Воронеж, Российская Федерация,
e-mail: ASoloviev58@yandex.ru,
ORCID: 0000-0002-6150-1090

Alexander S. Soloviev, Dr. Sci. (Engineering),
Professor, Voronezh Institute of the Federal
Penitentiary Service of Russia,
Voronezh, Russian Federation,
e-mail: ASoloviev58@yandex.ru,
ORCID: 0000-0002-6150-1090

Кузьменко Роман Валентинович, доктор физико-математических наук, доцент, профессор кафедры радиоэлектронных устройств и систем, Воронежский государственный технический университет; профессор кафедры математики и естественно-научных дисциплин, Воронежский институт Федеральной службы исполнения наказаний России, г. Воронеж, Российская Федерация, e-mail: roman_kuzmenko@inbox.ru

Калач Андрей Владимирович, доктор химических наук, профессор, заведующий кафедрой информационных технологий, моделирования и управления, Воронежский государственный университет инженерных технологий, г. Воронеж, Российская Федерация, e-mail: a_kalach@mail.ru, ORCID: 0000-0002-8926-3151

Roman V. Kuzmenko, Dr. Sci. (Physical and Mathematical), Associate Professor, Professor at the Department of Radioelectronic Devices and Systems, Voronezh State Technical University; Professor at the Department of Mathematics and Natural Sciences, Voronezh Institute of the Federal Penitentiary Service of Russia, Voronezh, Russian Federation, e-mail: roman_kuzmenko@inbox.ru

Andrew V. Kalach, Dr. Sci. (Chemical), Professor, Head of the Department of Information Technology, Modeling and Management, Voronezh State University of Engineering Technologies, Voronezh, Russian Federation, e-mail: a_kalach@mail.ru, ORCID: 0000-0002-8926-3151