

https://doi.org/10.51885/3134-8025_IICS_2026_3_4

МРНТИ 28.23.25

СУБЪЕКТ-СПЕЦИФИЧЕСКАЯ ОПТИМИЗАЦИЯ ПАЙПЛАЙНА ОБРАБОТКИ ЭЭГ-СИГНАЛОВ ДЛЯ МНОГОКЛАССОВОЙ КЛАССИФИКАЦИИ МОТОРНОГО ВОООБРАЖЕНИЯ

МОТОРЛЫҚ ЕЛЕСТЕТУДІҢ КӨПКЛАСТЫ КЛАССИФИКАЦИЯСЫ ҮШІН ЭЭГ-СИГНАЛДАРЫН ӨҢДЕУ ПАЙПЛАЙНЫН СУБЪЕКТ-СПЕЦИФИКАЛЫҚ ТҮРДЕ ОҢТАЙЛАҢДЫРУ

SUBJECT-SPECIFIC OPTIMIZATION OF THE EEG SIGNAL PROCESSING PIPELINE FOR MULTICLASS MOTOR IMAGERY CLASSIFICATION

Ж.Д. Кембаева ^{1*}, Г.Б. Досымбетова ¹, М.К. Нұрғалиев ¹

¹Казахский национальный университет имени аль-Фараби, г. Алматы, Казахстан

*Автор-корреспондент: Кембаева Жазира Дюсенбаевна, e-mail: zhazi0823@gmail.com

Ключевые слова:

ЭЭГ моторного
воображения, интерфейс
мозг-компьютер,
обработка ЭЭГ-сигналов,
метод общих
пространственных
шаблонов,
фильтробанковый метод
общих пространственных
шаблонов, субъект-
специфическая
оптимизация, вложенная
перекрёстная проверка.

АННОТАЦИЯ

Интерфейсы мозг-компьютер, основанные на задачах моторного воображения, требуют высокой точности классификации электроэнцефалографических сигналов, что является ключевым условием эффективного функционирования систем. Однако межсубъектная вариабельность и чувствительность сигналов к шумам существенно усложняют их обработку. Целью исследования является разработка и оценка эффективности субъект-специфической оптимизации пайплайна обработки электроэнцефалографических сигналов для многоклассовой классификации моторного воображения. В работе применён комплексный подход, включающий сегментацию сигналов, частотную и пространственную фильтрацию, извлечение признаков и классификацию. Проведено сравнение базовой и оптимизированной конфигураций с использованием перекрёстной проверки. Результаты показали, что индивидуальная настройка параметров обеспечивает повышение точности классификации. Наилучший результат достигнут при использовании логистической регрессии: точность составила 86,5 %, коэффициент каппа Коэна составил 0,82. Полученные результаты подтверждают эффективность предложенного подхода и его перспективность для разработки надёжных систем управления.

Түйінді сөздер:

моторлық елестету ЭЭГ,
ми-компьютер
интерфейсі, ЭЭГ-
сигналдарын өңдеу,
жалпы кеңістіктік үлгілер
әдісі, сүзгілер банкі
негізіндегі жалпы

ТҮЙІНДЕМЕ

Моторлық елестетуге негізделген ми-компьютер интерфейстері электроэнцефалографиялық сигналдарды жоғары дәлдікпен классификациялауды талап етеді, бұл жүйелердің тиімді жұмыс істеуінің негізгі шарты болып табылады. Алайда субъектілер арасындағы вариабельділік пен сигналдардың шуға сезімталдығы олардың өңделуін едәуір қиындатады. Зерттеудің мақсаты – моторлық елестетуді көпкласты классификациялау үшін электроэнцефа-



© 2026 Ж.Д. Кембаева, Г.Б. Досымбетова, М.К. Нұрғалиев

Данная работа распространяется на условиях лицензии

Creative Commons «С указанием авторства» 4.0 Международная (CC BY 4.0).

<https://creativecommons.org/licenses/by/4.0/>

кеңістіктік үлгілер әдісі,
субъект-спецификалық
оңтайландыру,
кірістірілген айқаспалы
тексеру.

логографиялық сигналдарды өңдеу пайплайнын субъект-спецификалық оңтайландырудың тиімділігін әзірлеу және бағалау. Жұмыста сигналдарды сегментациялау, жиіліктік және кеңістіктік фильтрация, белгілерді бөліп алу және классификацияны қамтитын кешенді тәсіл қолданылды. Базалық және оңтайландырылған конфигурациялар айқас тексеру әдісін қолдану арқылы салыстырылды. Нәтижелер параметрлерді жеке бейімдеу классификация дәлдігін арттыратынын көрсетті. Ең жоғары нәтиже логистикалық регрессияны қолдану кезінде алынды: дәлдік 86,5 %, каппа Коэн коэффициенті 0,82. Алынған нәтижелер ұсынылған тәсілдің тиімділігін және сенімді басқару жүйелерін әзірлеу үшін перспективтілігін растайды.

keywords:

Motor imagery EEG signals, Brain-computer interface (BCI), EEG signal processing, Common Spatial Pattern (CSP), Filter Bank CSP (FBCSP), Subject-specific optimization, Nested cross-validation.

ABSTRACT

Brain-computer interfaces based on motor imagery tasks require high classification accuracy of electroencephalographic signals, which is a key condition for effective system performance. However, inter-subject variability and sensitivity of the signals to noise significantly complicate their processing. The aim of this study was to develop and evaluate the effectiveness of subject-specific optimization of the electroencephalographic signal processing pipeline for multiclass motor imagery classification. A comprehensive approach was applied, including signal segmentation, frequency and spatial filtering, feature extraction, and classification. A comparison between baseline and optimized configurations was performed using cross-validation. The results showed that individual parameter tuning improves classification accuracy. The best performance was achieved using logistic regression, with an accuracy of 86.5% and a Cohen's kappa coefficient of 0.82. The results confirm the effectiveness of the proposed approach and its potential for developing reliable control systems.

ВВЕДЕНИЕ

Интерфейсы мозг-компьютер (BCI) являются одним из наиболее активно развивающихся направлений современной нейроинженерии и интеллектуальных человеко-машинных систем. Такие системы обеспечивают прямое взаимодействие между мозгом человека и внешними устройствами, минуя периферическую нервную систему. В связи с этим технологии BCI находят широкое применение в медицинской реабилитации, управлении робототехническими системами и разработке ассистивных технологий (Chaddad et al., 2023; Tangermann et al., 2012). Одним из наиболее распространённых методов регистрации мозговой активности в BCI является электроэнцефалография (ЭЭГ). К преимуществам данного метода относятся неинвазивность, высокая временная разрешающая способность и сравнительно низкая стоимость оборудования, тогда как к недостаткам — низкое отношение сигнал/шум, чувствительность к артефактам и межсубъектная вариабельность (Chaddad et al., 2023; Roy et al., 2019).

В задачах управления BCI широко используется парадигма моторного воображения, при которой пользователь мысленно представляет движение без его фактического выполнения. При этом изменения сенсомоторных ритмов могут регистрироваться с помощью ЭЭГ и быть использованы для формирования управляющих команд (Roy et al., 2019; Lawhern et al., 2018). Эффективность BCI-систем во многом зависит от качества обработки ЭЭГ-сигналов, поэтому в последние годы активно разрабатываются методы предварительной обработки, пространственной фильтрации, извлечения признаков и классификации (Wang et al., 2024; Hadi-Saleh et al., 2025).

Обработка ЭЭГ-сигналов осложняется влиянием артефактов, внешних помех и физиологических шумов (Anand et al., 2022; Coelli et al., 2024). В связи с этим важным этапом является построение полного пайплайна обработки сигналов. Выбор методов на каждом этапе существенно влияет на точность распознавания моторного воображения, а различные комбинации методов предварительной обработки могут приводить к значительным различиям в результатах классификации (Coelli et al., 2024; Malan & Sharma, 2021; Nguyen et al., 2023; Bandile, Philani & Clifford, 2025). Кроме того, корректный выбор временных интервалов и частотных диапазонов играет ключевую роль в повышении точности распознавания (Malan & Sharma, 2021; Nguyen et al., 2023; Bandile, Philani & Clifford, 2025; Kumari et al., 2024).

Для анализа сигналов моторного воображения широко применяются методы пространственной фильтрации, среди которых одним из наиболее распространённых является алгоритм Common Spatial Pattern (CSP), позволяющий эффективно различать сигналы различных классов (Ramoser, Muller-Gerking & Pfurtscheller, 2000). В дальнейшем были предложены его расширения, такие как Filter Bank Common Spatial Pattern (FBCSP), учитывающие спектральные особенности сигналов (Ang et al., 2012). Кроме того, в современных исследованиях активно рассматриваются методы оптимизации частотных диапазонов, временных окон и параметров моделей (Cao et al., 2025; Zhang et al., 2024).

После этапа извлечения признаков важную роль играет выбор классификатора. В задачах EEG-BCI широко применяются классические методы, такие как Linear Discriminant Analysis (LDA) со shrinkage-регуляризацией (линейный дискриминантный анализ с усадкой), Linear Support Vector Machine (SVM, линейный метод опорных векторов) и логистическая регрессия, обеспечивающие хороший баланс между точностью и вычислительной сложностью (Antony et al., 2022; Khan et al., 2023). Несмотря на то, что методы глубокого обучения способны достигать высокой точности, они требуют значительных вычислительных ресурсов и больших объёмов данных, что ограничивает их применение в реальном времени (Chen et al., 2025; Taghizadeh, Vaez & Faezipour, 2024; Titkanlou, Pham & Mouček, 2025; Shirodkar, Edla & Kumari, 2025; Murphy, 2012).

Для объективной оценки качества классификации широко используются методы кросс-валидации, позволяющие снизить риск переобучения и обеспечить надёжную оценку модели (Wilimitis & Walsh, 2023; Calle et al., 2025). В задачах многоклассовой классификации применяются такие метрики, как точность и коэффициент каппа Коэна, что позволяет комплексно оценить качество работы алгоритмов (Grandini, Bagli & Visani, 2020).

В качестве стандартного набора данных для оценки EEG-BCI алгоритмов широко используется BCI Competition IV Dataset 2a, содержащий многоканальные записи ЭЭГ-сигналов моторного воображения нескольких субъектов (Brunner, Leeb & Muller-Putz IV, 2008; Altuwaijri & Muhammad, 2022; Hwaidi & Ghanem, 2026).

Кроме того, большинство опубликованных исследований рассматривают оптимизацию отдельных этапов обработки ЭЭГ-сигналов (например, временной сегментации, частотной фильтрации или параметров CSP) независимо друг от друга, тогда как комплексная субъект-специфическая оптимизация полного пайплайна с последующим сравнением базовой и оптимизированной конфигураций, использованием вложенной перекрёстной проверки и статистической оценкой полученных улучшений представлена значительно реже. При этом параметры обработки, такие как временные интервалы и частотные диапазоны, существенно влияют на точность классификации (Coelli et al., 2024; Malan & Sharma, 2021; Nguyen et al., 2023; Bandile, Philani & Clifford, 2025). Кроме того, сравнительный анализ базовых и оптимизированных конфигураций пайплайна проводится относительно редко (Malan & Sharma, 2021; Nguyen et al., 2023; Hwaidi & Ghanem, 2026; Gómez-Morales et al., 2025). В связи с этим выдвигается гипотеза о том, что субъект-специфическая оптимизация параметров может повысить точность классификации.

В связи с этим возникает необходимость в разработке и анализе эффективных подходов к оптимизации параметров обработки ЭЭГ-сигналов. Целью данной работы является исследование влияния параметров пайплайна обработки ЭЭГ-сигналов на точность классификации моторного воображения и сравнительный анализ базовой и оптимизированной конфигураций. Для достижения поставленной цели в работе реализованы базовый и оптимизированный пайплайны обработки ЭЭГ-сигналов. Применена пространственная фильтрация на основе метода CSP с использованием классических алгоритмов классификации. Исследовано влияние временных окон и частотных диапазонов. Также выполнен сравнительный анализ результатов на наборе данных BCI Competition IV Dataset 2a.

Научная новизна работы заключается не только в оптимизации отдельных параметров обработки ЭЭГ-сигналов, но и в разработке комплексной процедуры субъект-специфической настройки полного пайплайна обработки. В отличие от существующих исследований, в которых преимущественно рассматривается оптимизация отдельных компонентов пайплайна (например, временных окон, частотных диапазонов или параметров CSP), в данной работе выполнена их совместная субъект-специфическая оптимизация, включающая временную сегментацию, банк частотных фильтров, параметры CSP/FBCSP, регуляризацию, гиперпараметры классификаторов, а также проведены сравнительный анализ базовой и оптимизированной конфигураций, оценка с использованием вложенной перекрёстной проверки и статистическая проверка значимости полученных улучшений.

Статья организована следующим образом: в разделе «Материалы и методы исследования» описаны используемый набор данных и методы обработки ЭЭГ-сигналов; в разделе «Результаты и их обсуждение» приведены результаты экспериментов и сравнительный анализ базовой и оптимизированной конфигураций обработки; в разделе «Заключение» представлены основные выводы и направления дальнейших исследований.

МАТЕРИАЛЫ И МЕТОДЫ ИССЛЕДОВАНИЯ

В данном исследовании для классификации сигналов моторного воображения использовался открытый набор данных BCI Competition IV Dataset 2a (2008) (Brunner, Leeb & Muller-Putz IV, 2008), содержащий записи ЭЭГ девяти субъектов (A01–A09). Датасет включает четыре класса моторного воображения (левая рука, правая рука, обе ноги и язык), обозначаемые событийными маркерами 769–772. Регистрация выполнялась с использованием 22 ЭЭГ-каналов и 3 каналов электроокулографии (ЭОГ), расположенных согласно международной системе 10–20. Частота дискретизации составляла 250 Гц; при записи применялась полосовая фильтрация 0,5–100 Гц и notch-фильтр на частоте 50 Гц.

Предварительная обработка выполнялась с использованием библиотеки MNE-Python и является обязательным этапом перед извлечением признаков и классификацией, поскольку исходные записи содержат шумы, биологические помехи, артефакты и межсубъектную вариабельность, затрудняющие выделение информативных компонентов (Chaddad et al., 2023). В рамках работы выполнялись отбор ЭЭГ-каналов, выделение событий, сегментация и частотная фильтрация сигналов. Для анализа использовались 22 ЭЭГ-канала, тогда как 3 ЭОГ-канала были исключены, поскольку артефакты электроокулографии могут исказить сигнал и снижать точность классификации. Дополнительные методы удаления артефактов (например, ICA или ASR) в настоящем исследовании не применялись.

Классификация моторного воображения основана на выделении сегментов ЭЭГ, синхронизированных с событиями эксперимента. Для обозначения классов используются маркеры 769–772, а начало сеанса отмечается маркером 32766. Каждый субъект выполнял 6 серий по 48 испытаний (12 на класс), всего 288 испытаний за одну сессию (72 на класс). Структура набора данных и организация событий представлены на рисунке 1.




Рисунок 1. Структура данных и организация событий в BCI Competition IV Dataset 2a
Примечание – составлено авторами

Сегментация является одним из ключевых этапов при построении ЭЭГ-пайплайна обработки сигналов. Сегментация (epoching) представляет собой процесс разделения непрерывной записи, синхронизированной с событиями, на фрагменты заданной длительности. В ряде исследований показано, что выбор параметров сегментации напрямую влияет на качество классификации (Coelli et al., 2024; Malan & Sharma, 2021). В базовой конфигурации использовалось фиксированное временное окно 2.0–6.0 с, одинаковое для всех субъектов. Однако проявление моторного воображения может возникать с различной задержкой у разных испытуемых, поэтому для повышения точности была реализована субъект-специфическая оптимизация временных окон. Рассматривались следующие интервалы: MI_W1 [1.5-4.0] с, MI_W2 [2.0-4.5] с, MI_W3 [2.5-5.0] с, MI_W4 [3.0-5.5] с. Для каждого субъекта последовательно оценивались все рассматриваемые временные окна. Для каждого варианта выполнялся полный цикл обработки и оценки модели с использованием одинаковой процедуры эксперимента. По результатам сравнения выбиралось временное окно, обеспечивающее наилучшее качество классификации. На рисунке 2 представлены временная структура эксперимента моторного воображения в наборе данных BCI Competition IV Dataset 2a и используемые окна сегментации ЭЭГ.




Рисунок 2. Временная структура эксперимента моторного воображения
в BCI Competition IV Dataset 2a и используемые окна сегментации ЭЭГ
Примечание – составлено авторами

Эксперимент включает этапы фиксации взгляда, предъявления подсказки, выполнения моторного воображения и паузы. Зелёным цветом обозначены

тестируемые временные интервалы сегментации (MI_W1–MI_W4), применяемые для выделения эпох ЭЭГ.

ЭЭГ-сигналы моторного воображения содержат информативные компоненты в диапазонах μ (8–12 Гц) и β (16–30 Гц). Для выделения сигналов в заданных частотных диапазонах применяется частотная фильтрация. Однако использование только одной полосы частот не всегда обеспечивает максимальное качество классификации. Для повышения эффективности сигнал может быть разделён на несколько поддиапазонов (filter bank) с последующей обработкой каждого из них. Такой подход используется в методе FBCSP и демонстрирует высокую эффективность (Malan & Sharma, 2021; Cao et al., 2025). В базовом пайплайне использовалась фиксированная полоса частот 8–30 Гц. В процессе оптимизации рассматривались следующие наборы частотных диапазонов:

FB1: [8–12] Гц, [12–16] Гц, [16–20] Гц, [20–24] Гц, [24–28] Гц, [28–32] Гц;

FB2: [7–11] Гц, [11–15] Гц, [15–19] Гц, [19–23] Гц, [23–27] Гц, [27–31] Гц;

FB3: [8–14] Гц, [14–20] Гц, [20–26] Гц, [26–32] Гц.

Таким образом, в работе использовались три варианта разбиения частотного диапазона: FB1 — классический вариант, FB2 — сдвинутая версия FB1_ и FB3 — расширенные частотные полосы.

Для получения информационных сигналов моторной визуализации ЭЭГ в данной работе использовались методы пространственной фильтрации CSP и ее многополосного расширения FBCSP. Особенностью этих методов является то, что они позволяют на основе анализа дисперсии ЭЭГ-сигналов получать пространственные данные, повышающие разность между классами моторного воображения.

Метод CSP преобразует исходный ЭЭГ-сигнал с помощью пространственной фильтрации:

$$Z = W^T E, \quad (1)$$

где: E – матрица ЭЭГ-сигнала (каналы×время);

W – матрица пространственного фильтра;

Z – сигнал в пространстве CSP, компонент.

Оптимальные фильтры CSP рассчитываются на основе задач, определяющих обобщенно-собственные значения:

$$\Sigma_1 W = (\Sigma_1 + \Sigma_2) W \Lambda, \quad (2)$$

где: Σ_1 және Σ_2 – ковариационные матрицы двух классов;

Λ – диагональная матрица собственных значений.

После вычисления матриц фильтров признаки вычисляются как логарифм нормированной дисперсии CSP-компонента:

$$v = \log \left(\frac{\text{diag}(W^T E E^T W)}{\text{tr}(W^T E E^T W)} \right). \quad (3)$$

После этих шагов размерность исходных сигналов уменьшается, а также появляются различия между классами моторного воображения (Ramoser, Muller-Gerking & Pfurtscheller, 2000; Ang et al., 2012).

С целью учета спектральных характеристик моторных ЭЭГ-сигналов был использован метод FBCSP. Этот метод заключается в разделении ЭЭГ-сигналов на несколько filter banks (K), и далее метод CSP применяется отдельно к каждой полосе частот ($v_{K,i}$). В результате полученные признаки объединяются в один вектор. Последний полученный вектор признаков формируется как конкатенация CSP-компонентов по всем полосам: $v_i = [v_{1,i}, v_{2,i}, \dots, v_{K,i}]$ (Ang et al., 2012).

Поскольку эффективность метода CSP зависит от параметров пространственной фильтрации, а также от субъекта и частотного диапазона, в рамках процедуры

оптимизации была проведена настройка параметров CSP. Измененные параметры: количество компонентов $i \in \{4,6,8,10,12\}$ и регуляризация ковариационных матриц $reg \in \{None, LedoitWolf, OAS\}$. Из этих параметров эффективные варианты выбирались индивидуально для каждого субъекта.

После извлечения признаков полученные CSP-компоненты v_i далее были переданы на вход классификатора. Для сравнения эффективности использовались 3 широко используемых метода классификации: LDA shrinkage, логистическая регрессия и Linear SVM. По сути, эти методы считаются базовыми моделями для ЭЭГ-сигналов моторного воображения (Khan et al., 2023).

Принцип работы метода LDA shrinkage основан на оценке векторов средних классов и общих ковариационных матриц. После этой оценки создается дискриминантная функция. В общем случае на основе этой функции принимается решение (Murphy, 2012):

$$\delta_c(v) = v_i^T \Sigma_{shr}^{-1} \mu_c - \frac{1}{2} \mu_c^T \Sigma_{shr}^{-1} \mu_c + \ln(\pi_c), \quad (4)$$

где: μ_c – средний вектор признаков класса c ;
 Σ – ковариационная матрица признаков;
 π_c – априорная вероятность класса c .

Для повышения стабильности оценки ковариации использовалась регуляризация shrinkage, реализованная в стандартной модели LDA. Итоговый класс определялся по следующему правилу:

$$\hat{y}_i = \arg \max_c \delta_c(v_i). \quad (5)$$

Логистическая регрессия является вероятностным классификатором. Для многоклассовой классификации вероятность вектора признаков f , относящегося к классу c , определяется функцией softmax (Murphy, 2012):

$$P(y = c|v_i) = \frac{\exp(w_c^T v_i + b_c)}{\sum_{j=1}^C \exp(w_j^T v_i + b_j)}, \quad (6)$$

где: w_c – весовой вектор для класса c ;
 b_c – параметр bias.

А для принятия решения используется следующая функция:

$$\hat{y}_i = \arg \max_c P(y = c|v_i). \quad (7)$$

Одним из используемых методов классификации является Linear SVM. Этот метод считается надежным классификатором, широко используемым как для бинарной классификации, так и для многоклассовой классификации. Основная функция решения основана на функции (Murphy, 2012):

$$g_c(v_i) = w_c^T v_i + b_c. \quad (8)$$

Особенностью этого метода является максимальное определение разностной границы между классами, в результате чего он может работать с ЭЭГ-признаками высокого уровня шума и повышать устойчивость (Antony et al., 2022). Окончательный класс определяется с помощью следующей функции (Murphy, 2012):

$$\hat{y}_i = \arg \max_c g_c(v_i). \quad (9)$$

В ходе работы была выполнена настройка параметра регуляризации C для классификаторов Linear SVM и логистической регрессии: $C \in \{0,1; 1; 10\}$.

После выбора оптимального временного окна выполнялась субъект-специфическая настройка гиперпараметров. В процессе оптимизации последовательно оценивались

различные конфигурации банка фильтров, числа CSP-компонентов и методов регуляризации ковариационной матрицы. После формирования признакового пространства проводилось сравнение трёх классификаторов: Shrinkage LDA, логистической регрессии и Linear SVM. Для классификаторов логистическая регрессия и Linear SVM дополнительно оптимизировался параметр регуляризации C . Оптимальной считалась конфигурация, обеспечивающая максимальное среднее значение коэффициента каппа Коэна по результатам процедуры оптимизации.

Для разделения этапов подбора гиперпараметров и независимой оценки модели использовалась стратегия вложенной перекрёстной проверки, снижающая риск переобучения и утечки информации из тестовой выборки (Wilimitis & Walsh, 2023; Calle et al., 2025). Внешний цикл был реализован методом GroupKFold ($K_{outer} = 5$), а внутренняя кросс-валидация - ($K_{inner} = 3$) - применялся для выбора оптимальной конфигурации гиперпараметров. После завершения внутреннего цикла модель с найденной конфигурацией повторно обучалась на всей обучающей части соответствующего внешнего фолда и только затем оценивалась на независимой тестовой выборке внешнего цикла. Итоговые показатели качества рассчитывались исключительно по результатам внешнего цикла. Тестовая выборка не использовалась ни при подборе гиперпараметров, ни при обучении модели, что исключало утечку информации между этапами обучения и тестирования. Схема организации процедуры вложенной перекрёстной проверки представлена на рисунке 3.




Рисунок 3. Организация внешнего и внутреннего циклов вложенной перекрёстной проверки

Примечание – составлено авторами

Применена базовая метрика оценки качества точность (*Accuracy*), рассчитывается следующим образом:

$$Accuracy = \frac{TP+TN}{(TP+TN+FP+FN)}, \quad (10)$$

где: TP – число истинно положительных наблюдений;

TN – число истинно отрицательных наблюдений;

FP – число ложноположительных наблюдений;

FN – число ложноотрицательных наблюдений.

Дополнительная метрика коэффициент каппа Коэна (*Cohen's kappa*) была вычислена, эта метрика вычисляет согласованность между истинными метками и предполагаемой моделью с вероятностью случайного совпадения и обеспечивает более точную оценку качества модели по сравнению с величиной *Accuracy* (Grandini, Bagli & Visani, 2020; Altuwaijri & Muhammad, 2022):

$$Cohen's\ kappa = \frac{Po - Pe}{1 - Pe}, \quad (11)$$

где: P_o – наблюдаемая доля совпадений (фактический *Accuracy*);

P_e – ожидаемая доля совпадений при случайном обнаружении.

Для оценки статистической значимости улучшения результатов после субъект-специфической оптимизации использовался парный критерий знаковых рангов Уилкоксона (Wilcoxon signed-rank test). Данный непараметрический критерий применяется для сравнения двух зависимых выборок и не требует предположения о нормальном распределении данных, что делает его подходящим для анализа результатов, полученных на небольшом количестве субъектов (Demšar, 2006).

Для каждого субъекта вычислялась разность d_i между значениями *Accuracy* оптимизированной и базовой моделей:

$$d_i = Accuracy_{Tuned,i} - Accuracy_{Baseline,i}. \quad (12)$$

После ранжирования абсолютных значений различий статистика критерия определялась как:

$$W = \min(R^+, R^-),$$

где: R^+ – сумма рангов положительных различий;

R^- – сумма рангов отрицательных различий.

Различия считались статистически значимыми при $p < 0,05$ (Demšar, 2006).

На рисунке 4 представлена общая схема экспериментального пайплайна обработки ЭЭГ-сигналов, реализованного в данной работе.




Рисунок 4. Общая схема экспериментального пайплайна

Примечание – составлено авторами

РЕЗУЛЬТАТЫ И ИХ ОБСУЖДЕНИЕ

В первом эксперименте были выбраны постоянные параметры для обработки и классификации сигналов, а также оценена способность базовой конфигурации пайплайна. Для всех субъектов применялись одинаковые временные границы эпох моторного воображения, фиксированная полоса частот, неизменные параметры пространственной фильтрации и классификаторов. Наилучший результат среди протестированных моделей показал классификатор логистической регрессии: точность классификации составила 82,5%, а коэффициент каппа Коэна составил 0,77.

Распределение показателей по субъектам и классификаторам показано на рисунке 5. Можно заметить, что способность моделей различается между субъектами и между алгоритмами. Кроме того, некоторые субъекты не показали стабильных хороших результатов ни в одном классификаторе.




Рисунок 5. Метрики качества классификации для базовой конфигурации

Примечание – составлено авторами

Во второй части эксперимента использовалась комплексная оптимизация субъект-специфических параметров. Оптимизированы временные границы эпох моторного воображения, параметры частотной фильтрации, параметры пространственной фильтрации CSP, а также гиперпараметры классификаторов. Для каждого субъекта выбиралась конфигурация гиперпараметров, обеспечивающая максимальное значение коэффициента каппа Коэна по результатам процедуры вложенной перекрёстной проверки. Самый высокий результат в случае использования оптимизированного пайплайна показал классификатор логистической регрессии: точность составила 86,5 %, а коэффициент каппа Коэна – 0,82.




Рисунок 6. Метрики качества классификации для оптимизированной конфигурации

Примечание – составлено авторами

Для каждого субъекта в процессе субъект-специфической оптимизации была получена индивидуальная конфигурация параметров обработки ЭЭГ-сигналов. Оптимальные комбинации временных окон, банка фильтров, параметров CSP/FBCSP и классификаторов представлены в таблице 1.

Таблица 1. Оптимальные параметры субъект-специфической конфигурации для каждого субъекта

Субъект	Временное окно, с	Filter Bank	CSP-компоненты	Регуляризация CSP	Лучший классификатор
A01	1.5–4.0	FB2	8	None	Shrinkage LDA
A02	3.0–5.5	FB2	4	Ledoit–Wolf	Linear SVM
A03	1.5–4.0	FB3	4	None	LogReg
A04	1.5–4.0	FB3	12	Ledoit–Wolf	Shrinkage LDA
A05	3.0–5.5	FB2	4	None	Shrinkage LDA
A06	1.5–4.0	FB1	6	Ledoit–Wolf	Shrinkage LDA
A07	1.5–4.0	FB1	10	None	LogReg
A08	1.5–4.0	FB2	10	Ledoit–Wolf	LogReg
A09	1.5–4.0	FB3	12	None	LogReg

Примечание – составлено авторами

Визуализация результата оптимизированного пайплайна показана на рисунке 6. По сравнению с результатом базовой конфигурации можно наблюдать увеличение значений точности для ряда испытуемых _____ и коэффициента каппа Коэна. Это показывает, что на эффективность классификации положительно повлиял результат многофакторной оптимизации.




Рисунок 7. Сравнение точности классификации между базовым и оптимизированным алгоритмами для каждого субъекта

Примечание – составлено авторами

На рисунке 7 сравниваются точность классификации (Accuracy (%)) и соответствующее изменение показателя (Δ Accuracy, в процентных р.р.) базового и оптимизированного пайплайнов с использованием 3 классификаторов (LDA, логистической регрессии, LinSVM) для каждого субъекта. В результате настройки гиперпараметров для большинства субъектов наблюдался рост показателей классификации. Наиболее заметное увеличение наблюдалось у субъекта A03T: повышение точности, в зависимости от типа классификатора, составило от +17 р.р. до +20 р.р. Значительное увеличение наблюдалось у субъектов A04T, A06T, A08T и A09T (+4 р.р. до +16 р.р.). Для субъекта A07T увеличение было меньше (+1 р.р. до +4 р.р.), что свидетельствует о близости базовой конфигурации к оптимальной.

Таблица 2. Количественные результаты классификации для всех субъектов после субъект-специфической оптимизации

Субъект	Лучший классификатор	Accuracy (%)	Cohen's Kappa	Δ Accuracy (p.p.)
A01T	Shrinkage LDA	75.0	0.67	+3.6
A02T	Linear SVM	69.0	0.59	+5.5
A03T	LogReg	86.5	0.82	+20.5
A04T	Shrinkage LDA	55.0	0.40	+11.0
A05T	Shrinkage LDA	68.7	0.58	-3.9
A06T	Shrinkage LDA	46.0	0.28	+8.0
A07T	LogReg	84.6	0.79	+2.1
A08T	LogReg	82.1	0.76	+14.0
A09T	LogReg	49.8	0.33	+13.5
Примечание – составлено авторами				

Однако для субъекта A05T настройка гиперпараметров привела к снижению точности классификации (в диапазоне от -3 р.р. -8 р.р.). Таким образом, эффект оптимизации гиперпараметров был неоднородным и зависел от индивидуальных характеристик данных. В целом результаты показали преимущество индивидуальной настройки для каждого субъекта по сравнению с фиксированной базовой конфигурацией. Подробные количественные результаты классификации для каждого субъекта представлены в таблице 2.

Для оценки статистической значимости улучшения точности после субъект-специфической оптимизации был применен парный критерий знаковых рангов Уилкоксона. Результаты представлены в таблице 3.

Таблица 3. Результаты статистической оценки значимости улучшения точности с использованием критерия Уилкоксона

Классификатор	Baseline Accuracy, %	Tuned Accuracy, %	Средний прирост, p.p.	W	p-value
LDA	58.96	67.36	+8,41	2	0.0117
LogReg	60.46	67.78	+7,31	5	0.0391
Linear SVM	58.51	65.44	+6,93	5	0.0391
Примечание – составлено авторами					

Как видно из таблицы 3, для всех исследованных классификаторов получены статистически значимые различия между базовой и оптимизированной конфигурациями ($p < 0,05$). Наибольший средний прирост точности наблюдался для классификатора LDA (+8,41 р.р.), тогда как для логистической регрессии и Linear SVM прирост составил +7,31 и +6,93 р.р. соответственно.

На рисунке 8 представлены иллюстрации, позволяющие оценить структуру ошибок классификации, а также выявить специфические временные и частотные характеристики сигнала. На рисунке 8 (а) изображены матрицы ошибок классификаторов LDA, логистической регрессии и LinSVM для субъекта A03T, показавшие наилучшие результаты, в оптимальном временном окне 1,5–4,0 с. Для всех моделей наблюдается явное преобладание элементов главной диагонали, что указывает на высокую точность классификации для всех 4 классов двигательного воображения. Наилучший показатель (0,89–0,90) продемонстрировал классификатор логистической регрессии. Основные ошибки классификации связаны с взаимными ошибками классов 2 и 3, что наиболее заметно в классификаторе LDA (до 19% ошибки в одном направлении). Однако в этом случае доля правильных предсказаний для каждого класса превышает 78%.





Рисунок 8. Матрицы ошибок (а) и карта важности признаков (б) классификаторов LDA, логистической регрессии и LinSVM для лучшего субъекта (A03T)

Примечание – составлено авторами

На дополнительном рисунке 8 (b) показана карта важности признаков. Карта важности признаков демонстрирует значимость различных частотных диапазонов в нескольких временных окнах. Классификатор логистической регрессии был выбран из-за его превосходной производительности. Из иллюстрации видно, что частотные диапазоны 12-16 Гц и 8-12 Гц вносят значительный вклад, особенно во временном окне 1,5-4,0 с. Это согласуется с физиологическими особенностями двигательного воображения. Полученные результаты позволяют перейти к их интерпретации и обсуждению.

Результаты показывают, что применение субъект-специфически настроенных параметров для каждого субъекта способствует улучшению результатов. Как показано на рисунке 7 и в таблицах 1–2, переход от фиксированной базовой конфигурации к субъект-специфической конфигурации в большинстве случаев сопровождается повышением точности классификации. Эти результаты согласуются с исследованиями, показавшими, что правильный выбор параметров сегментации сигнала и частотных диапазонов существенно влияет на качество декодирования двигательного воображения (Malan & Sharma, 2021; Nguyen et al., 2023).

Одним из наиболее ярких результатов является повышение точности примерно на 17–20% процентных пунктов для субъекта A03T. Это указывает на то, что базовая конфигурация не смогла полностью разделить информативные временные и частотные характеристики сигнала для этого субъекта. Использование альтернативных временных окон и нескольких частотных диапазонов позволило более точно разделить компоненты, связанные с мысленным представлением движений. Анализ матрицы ошибок (рис. 8) показал, что основные элементы расположены вдоль диагонали, что указывает на высокую точность классификации для всех 4 классов. Ошибки в основном наблюдались между классами 2 и 3, что является нормальным явлением для задач BCI, связанных с мысленным представлением движений, и может быть объяснено частичным перекрытием сигналов. Карта важности признаков (рис. 8 (б)) показала, что наиболее информативными диапазонами были 8–12 Гц и 12–16 Гц, особенно в интервале 1,5–4,0 с. Эти диапазоны соответствуют сенсомоторным μ - и β -ритмам и, как известно, широко используются в системах BCI (Tangermann et al., 2012; Ang et al., 2012).

Качество классификации также зависело от оптимизации параметров пространственной фильтрации CSP. Как видно из таблицы 1, для различных субъектов были выбраны разные комбинации временных окон, банка фильтров, количества CSP-компонентов и типа регуляризации, что подтверждает необходимость субъект-специфической настройки параметров. Эффективность CSP зависит от количества компонентов и способа настройки ковариационных матриц, поскольку эти параметры определяют степень пространственного разделения классов двигательного воображения (Ramoser, Muller-Gerking & Pfurtscheller, 2000).

Кроме того, оптимизация гиперпараметров не дала согласованных результатов для всех субъектов. Как следует из таблицы 2, в большинстве случаев оптимизированный пайплайн обеспечил повышение точности, однако для субъекта A05T результаты ухудшились. Это может быть связано с тем, что базовая конфигурация уже была близка к оптимальной для данного субъекта, вследствие чего дополнительная настройка параметров не привела к дальнейшему улучшению качества классификации. Кроме того, изменение временных окон, частотных диапазонов и параметров CSP могло привести к исключению части информативных признаков, которые эффективно использовались в базовой конфигурации.

Другим важным фактором является межсубъектная вариабельность (Chaddad et al., 2023), поскольку оптимальные частотные диапазоны и временные окна различны для

каждого человека. Следовательно, обобщаемость выбранных параметров может быть снижена.

В целом полученные результаты показали, что подход с индивидуальной настройкой параметров более эффективен, чем фиксированная конфигурация. Однако эффективность найденных параметров различается между субъектами и не обеспечивает одинакового прироста точности для всех пользователей. При этом для большинства субъектов субъект-специфическая оптимизация обеспечивала повышение точности независимо от используемого классификатора (LDA, логистическая регрессия и Linear SVM), что указывает на согласованность полученного эффекта оптимизации для различных классификаторов. Вместе с тем результаты для субъекта A05T показывают, что оптимальные параметры не являются универсальными и должны определяться индивидуально с учетом особенностей ЭЭГ каждого пользователя. Это подтверждает целесообразность субъект-специфической настройки пайплайна обработки ЭЭГ вместо использования единой фиксированной конфигурации для всех пользователей. Вместе с тем анализ оптимальных конфигураций (таблица 1) показал, что отдельные параметры повторялись для нескольких субъектов. В частности, временное окно 1,5–4,0 с оказалось оптимальным для большинства испытуемых, тогда как выбор банка фильтров и параметров CSP варьировался индивидуально. Это позволяет предположить, что некоторые параметры обладают большей устойчивостью, тогда как другие требуют субъект-специфической настройки.

Полученные результаты также подтверждаются статистическим анализом (таблица 3). Критерий знаковых рангов Уилкоксона показал статистически значимое повышение точности после субъект-специфической оптимизации для всех исследованных классификаторов ($p < 0,05$). Следовательно, наблюдаемое повышение точности не может быть объяснено случайными колебаниями результатов. Полученные результаты подтверждают, что наблюдаемое улучшение точности связано с использованием предложенной процедуры субъект-специфической оптимизации.

В исследовании также была подтверждена эффективность классификаторов. CSP + модели (LDA, LogReg, SVM) показали высокие результаты на данном наборе данных (рис. 5, рис. 6). В литературе указывается, что средняя точность таких подходов находится в диапазоне 70–85% (Roy et al., 2019; Lawhern et al., 2018; Khan et al., 2023). В данной работе логистическая регрессия дала наилучшие результаты с точностью 86,5% и коэффициентом каппа Коэна 0,82 в оптимизированной конфигурации. Это указывает на то, что признаки CSP хорошо аппроксимируются с данными моделями и что эти модели эффективны. Кроме того, данные классификаторы характеризуются низкой вычислительной сложностью, стабильностью и простотой интерпретации и поэтому подходят для систем BCI реального времени (Lawhern et al., 2018; Nguyen et al., 2023).

Ограничением исследования является тот факт, что эксперимент проводился только на одном наборе данных (BCI Competition IV Dataset IIa). Хотя этот набор данных широко используется, нет гарантии, что результаты будут полностью воспроизведены на других наборах данных. Кроме того, использовались только классические методы пространственной фильтрации и три классификатора, а более сложные модели могли бы еще больше повысить точность классификации.

Перспективным направлением будущих исследований является использование адаптивных к пользователю методов BCI, автоматического выбора гиперпараметров, а также глубокого обучения и гибридных моделей, которые автоматически обнаруживают пространственно-временную структуру. Также важно адаптировать эти методы для работы в реальном времени.

ЗАКЛЮЧЕНИЕ

В данной работе разработан и исследован комплексный пайплайн обработки ЭЭГ-сигналов для многоклассовой классификации моторного воображения. Проведено сравнение базовой конфигурации с фиксированными параметрами и оптимизированной конфигурации, учитывающей индивидуальные особенности субъектов. Оптимизация включала подбор временных окон сегментации, частотных диапазонов фильтрации, параметров пространственной фильтрации CSP и гиперпараметров классификаторов. Полученные результаты подтверждают эффективность субъект-специфической оптимизации, приводящей к улучшению качества классификации. В базовой конфигурации средняя точность составила около 82,5 %, а коэффициент каппа Коэна – 0,77, тогда как в оптимизированной конфигурации точность возросла до 86,5 %, а коэффициент каппа Коэна - до 0,82. Для отдельных субъектов наблюдалось более выраженное улучшение показателей. Так, для субъекта A03T прирост точности составил +17–20 процентных пунктов. Эти результаты подтверждают эффективность индивидуальной настройки параметров при обработке ЭЭГ-сигналов. В то же время выявленная межсубъектная вариабельность и нестабильность результатов оптимизации указывают на необходимость дальнейшего развития адаптивных и персонализированных методов обработки ЭЭГ-сигналов.

КОНФЛИКТ ИНТЕРЕСОВ: Авторы заявляют об отсутствии конфликта интересов.

ФИНАНСИРОВАНИЕ: Данное исследование выполнено в рамках подготовки диссертации на соискание степени доктора философии (PhD) по государственному образовательному заказу без привлечения дополнительного грантового финансирования.

ЗАЯВЛЕНИЕ О ДОСТУПНОСТИ ДАННЫХ: Данные, использованные в данном исследовании, являются общедоступными и предоставлены в рамках BCI Competition IV Dataset 2a. Доступ к набору данных можно получить по адресу: <https://www.bbc.de/competition/iv/>.

БЛАГОДАРНОСТИ: Авторы выражают благодарность анонимным рецензентам за ценные замечания, а также коллегам за обсуждение результатов исследования.

УВЕДОМЛЕНИЕ ОБ ИСПОЛЬЗОВАНИИ ТЕХНОЛОГИЙ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА: Авторы заявляют, что при подготовке данной рукописи были использованы технологии генеративного искусственного интеллекта (ChatGPT) с целью языковой и стилистической корректировки текста. Ответственность за точность, полноту и соответствие научным стандартам всего представленного материала полностью возложена на авторов.

СПИСОК ЛИТЕРАТУРЫ

- Altuwaijri, G. A., & Muhammad, G. (2022). A multibranch of convolutional neural network models for electroencephalogram-based motor imagery classification. *Biosensors*, 12(1), 22. <https://doi.org/10.3390/bios12010022>
- Anand, R., Radharapu, N., Pradhan, P., & Birok, R. (2022). Removal of EOG Artefact from EEG – A Review. *Advanced Production and Industrial Engineering*; IOS Press: Amsterdam, The Netherlands, 477-484. <https://doi.org/10.3233/ATDE220783>
- Ang, K. K., Chin, Z. Y., Wang, C., Guan, C., & Zhang, H. (2012). Filter bank common spatial pattern algorithm on BCI competition IV datasets 2a and 2b. *Frontiers in neuroscience*, 6, 39. <https://doi.org/10.3389/fnins.2012.00039>
- Antony, M. J., Sankaralingam, B. P., Mahendran, R. K., Gardezi, A. A., Shafiq, M., Choi, J. G., & Hamam, H. (2022). Classification of EEG using adaptive SVM classifier with CSP and

- online recursive independent component analysis. *Sensors*, 22(19), 7596. <https://doi.org/10.3390/s22197596>
- Bandile, M., Philani, K., & Clifford, M. R. (2025). Signal Preprocessing, Decomposition and Feature Extraction Methods in EEG-Based BCIs. *Applied Sciences*, 15(22), 12075. <https://doi.org/10.3390/app152212075>
- Brunner, C., Leeb, R., & Muller-Putz IV, G. (2008). BCI Competition IV Dataset 2a: 4-Class Motor Imagery. Graz University of Technology: Graz, Austria. https://www.bbci.de/competition/iv/desc_2a.pdf
- Calle, P., Bates, A., Reynolds, J. C., Liu, Y., Cui, H., Ly, S., ... & Pan, C. (2025). Integration of nested cross-validation, automated hyperparameter optimization, high-performance computing to reduce and quantify the variance of test performance estimation of deep learning models. *Computer methods and programs in biomedicine*, 109063. <https://doi.org/10.1016/j.cmpb.2025.109063>
- Cao, Y., Ding, J., Zhao, Z., He, Y., Fu, M., Liu, X., & Lyv, X. (2025). Improved filter bank common spatial pattern algorithm based on the sparrow search algorithm. *Frontiers in Human Neuroscience*, 19, 1679329. <https://doi.org/10.3389/fnhum.2025.1679329>
- Chaddad, A., Wu, Y., Kateb, R., & Bouridane, A. (2023). Electroencephalography signal processing: A comprehensive review and analysis of methods and techniques. *Sensors*, 23(14), 6434. <https://doi.org/10.3390/s23146434>
- ChatGPT. (2026/03/27). Language editing of scientific manuscript [Large language model]. OpenAI. <https://chat.openai.com>
- Chen, W., Xu, S., Hu, Q., Peng, Y., Zhang, H., Zhang, J., & Chen, Z. (2025). A Novel Deep Learning Model for Motor Imagery Classification in Brain–Computer Interfaces. *Information*, 16(7), 582. <https://doi.org/10.3390/info16070582>
- Coelli, S., Calcagno, A., Cassani, C. M., Temporiti, F., Reali, P., Gatti, R., ... & Bianchi, A. M. (2024). Selecting methods for a modular EEG pre-processing pipeline: An objective comparison. *Biomedical Signal Processing and Control*, 90, 105830. <https://doi.org/10.1016/j.bspc.2023.105830>
- Demšar, J. (2006). Statistical comparisons of classifiers over multiple data sets. *Journal of Machine learning research*, 7(Jan), 1-30.
- Gómez-Morales, Ó. W., Collazos-Huertas, D. F., Álvarez-Meza, A. M., & Castellanos-Dominguez, C. G. (2025). EEG Signal prediction for motor imagery classification in brain–computer interfaces. *Sensors*, 25(7), 2259. <https://doi.org/10.3390/s25072259>
- Grandini, M., Bagli, E., & Visani, G. (2020). Metrics for multi-class classification: an overview. *arXiv preprint arXiv:2008.05756*.
- Hadi-Saleh, Z., Mosleh, M., Al-Shahe, M. A., & Mosleh, M. (2025). Towards decoding motor imagery from EEG signal using optimized back propagation neural network with honey badger algorithm. *Scientific Reports*, 15(1), 21202. <https://doi.org/10.1038/s41598-025-05423-0>
- Hwaidi, J., & Ghanem, M. C. (2026). Motor imagery EEG signal classification using minimally random convolutional kernel transform and hybrid deep learning. *NeuroImage*, 328, 121816. <https://doi.org/10.1016/j.neuroimage.2026.121816>
- Khan, R. A., Rashid, N., Shahzaib, M., Malik, U. F., Arif, A., Iqbal, J., ... & Tiwana, M. (2023). A novel framework for classification of two-class motor imagery EEG signals using logistic regression classification algorithm. *Plos one*, 18(9), e0276133. <https://doi.org/10.1371/journal.pone.0276133>
- Kumari, A., Edla, D. R., Reddy, R. R., Jannu, S., Vidyarthi, A., Alkhayyat, A., & De Marin, M. S. G. (2024). EEG-based motor imagery channel selection and classification using hybrid

- optimization and two-tier deep learning. *Journal of Neuroscience Methods*, 409, 110215. <https://doi.org/10.1016/j.jneumeth.2024.110215>
- Lawhern, V. J., Solon, A. J., Waytowich, N. R., Gordon, S. M., Hung, C. P., & Lance, B. J. (2018). EEGNet: a compact convolutional neural network for EEG-based brain-computer interfaces. *Journal of neural engineering*, 15(5), 056013. <https://doi.org/10.1088/1741-2552/aace8c>
- Malan, N. S., & Sharma, S. (2021). Time window and frequency band optimization using regularized neighbourhood component analysis for multi-view motor imagery EEG classification. *Biomedical Signal Processing and Control*, 67, 102550. <https://doi.org/10.1016/j.bspc.2021.102550>
- Murphy, K. P., (2012). *Machine Learning: A Probabilistic Perspective*. MIT Press.
- Nguyen, M. T. D., Xuan, N. Y. P., Pham, B. M., Do, H. T. M., Phan, T. N. M., Nguyen, Q. T. T., & Ha, H. T. T. (2023). Optimize temporal configuration for motor imagery-based multiclass performance and its relationship with subject-specific frequency. *Informatics in Medicine Unlocked*, 36, 101141. <https://doi.org/10.1016/j.imu.2022.101141>
- Ramoser, H., Muller-Gerking, J., & Pfurtscheller, G. (2000). Optimal spatial filtering of single trial EEG during imagined hand movement. *IEEE transactions on rehabilitation engineering*, 8(4), 441-446. <https://doi.org/10.1109/86.895946>
- Roy, Y., Banville, H., Albuquerque, I., Gramfort, A., Falk, T. H., & Faubert, J. (2019). Deep learning-based electroencephalography analysis: a systematic review. *Journal of neural engineering*, 16(5), 051001. <https://doi.org/10.1088/1741-2552/ab260c>
- Shirodkar, V. R., Edla, D. R., & Kumari, A. (2025). Advancing Motor Imagery EEG Classification through Wavelet Scattering Transforms and 1D Transformers. *Procedia Computer Science*, 258, 2860-2869. <https://doi.org/10.1016/j.procs.2025.04.546>
- Taghizadeh, M., Vaez, F., & Faezipour, M. (2024). EEG motor imagery classification by feature extracted deep 1D-CNN and semi-deep fine-tuning. *IEEE Access*, 12, 111265-111279. <https://doi.org/10.1109/ACCESS.2024.3430838>
- Tangemann, M., Müller, K. R., Aertsen, A., Birbaumer, N., Braun, C., Brunner, C., ... & Blankertz, B. (2012). Review of the BCI competition IV. *Frontiers in neuroscience*, 6, 55. <https://doi.org/10.3389/fnins.2012.00055>
- Titkanlou, M. K., Pham, D. T., & Mouček, R. (2025). Classification of EEG signal using deep learning architectures-based motor-imagery for an upper-limb rehabilitation exoskeleton. *SN Computer Science*, 6(3), 193. <https://doi.org/10.1007/s42979-025-03743-6>
- Wang, X., Liesaputra, V., Liu, Z., Wang, Y., & Huang, Z. (2024). An in-depth survey on deep learning-based motor imagery electroencephalogram (EEG) classification. *Artificial intelligence in medicine*, 147, 102738. <https://doi.org/10.1016/j.artmed.2023.102738>
- Wilimitis, D., & Walsh, C. G. (2023). Practical considerations and applied examples of cross-validation for model development and evaluation in health care: tutorial. *Jmir ai*, 2, e49023. <http://dx.doi.org/10.2196/49023>
- Zhang, H., Zhao, Z., Liu, C., Duan, M., Lu, Z., & Wang, H. (2024). Classification of motor imagery EEG signals using wavelet scattering transform and Bi-directional long short-term memory networks. *Biocybernetics and Biomedical Engineering*, 44(4), 874-884. <https://doi.org/10.1016/j.bbe.2024.11.003>

Авторлар туралы мәліметтер
Информация об авторах
Information about authors



Кембаева Жазира Дюсенбаевна – техникалық ғылымдар магистрі, әл-Фараби атындағы Қазақ Ұлттық университеті, Алматы қ., Қазақстан,

Кембаева Жазира Дюсенбаевна – магистр технических наук, Казахский национальный университет им. аль-Фараби, г. Алматы, Казахстан,

Kembayeva Zhazira – Master of Technical Sciences, al-Farabi Kazakh National university, Almaty, Kazakhstan,
e-mail: zhazi0823@gmail.com ,
ORCID: <https://orcid.org/0009-0006-6557-4816>



Досымбетова Гулбахар Базарбаевна – PhD, әл-Фараби атындағы Қазақ Ұлттық университеті, Алматы, Қазақстан,

Досымбетова Гулбахар Базарбаевна – PhD, Казахский национальный университет им. аль-Фараби, г. Алматы, Казахстан,

Dosymbetova Gulbakhar – PhD, al-Farabi Kazakh National university, Almaty, Kazakhstan,
e-mail: gulbakhard@gmail.com ,
ORCID: <https://orcid.org/0000-0002-3935-7213>



Нұрғалиев Мадияр Кәменұлы – PhD, доцент, әл-Фараби атындағы Қазақ Ұлттық университеті, Алматы қ., Қазақстан,

Нурғалиев Мадияр Каменович – PhD, доцент, Казахский национальный университет им. аль-Фараби, г. Алматы, Казахстан,

Nurgaliyev Madiyar – PhD, Associate Professor, al-Farabi Kazakh National university, Almaty, Kazakhstan,
e-mail: johnatlantgalt@gmail.com ,
ORCID: <https://orcid.org/0000-0002-6795-5384>