

ИНФОРМАЦИОННЫЕ
ТЕХНОЛОГИИ
И ТЕЛЕКОММУНИКАЦИИ

INFORMATION
TECHNOLOGIES
AND TELECOMMUNICATIONS

УДК 004.5

DOI: 10.17212/2782-2001-2025-3-45-68

Индивидуальный подход к выбору частоты фотостимуляции в системах ИМК на основе SSVEP-парадигмы и моделей машинного обучения*

А.В. КОЗИН^а, А.К. ГЕРАСИМОВ^б, М.А. БАКАЕВ^с

630073, г. Новосибирск, пр. К. Маркса, 20, Новосибирский государственный техни-
ческий университет (НГТУ-НЭТИ)

^а JasderoR440@gmail.com ^б geraplusplus@gmail.com ^с bakaev@corp.nstu.ru

Интерфейсы «мозг – компьютер» (ИМК) предоставляют своим пользователям альтерна-
тивные каналы взаимодействия с периферийными устройствами различного назначения и явля-
ются важным направлением в области медицины и нейрореабилитации. Существует множество
парадигм построения подобных систем, каждая из которых обладает своими особенностями.
Одной из них является парадигма на основе устойчивых визуально вызванных потенциалов
(УВВП, англ. Steady-State Visually Evoked Potentials – SSVEP). Ее отличительной чертой явля-
ются низкие требования к предварительному обучению пользователя для эксплуатации ИМК.
При этом для нее характерна индивидуальная вариабельность реакции пользователей на фото-
стимулы, что вызывает определенные трудности. В существующих на данный момент исследо-
ваниях отмечается, что учет этой особенности может стать важным шагом к повышению точно-
сти и эффективности работы данного вида ИМК.

С развитием области машинного обучения (МО) всё чаще различные его методы исполь-
зуются для анализа биомедицинских сигналов. Предлагаются новые модели и архитектуры,
предназначенные для специфичной работы в какой-либо области. Это касается и ИМК, где МО
применяется с целью классификации входных данных, представленных в виде отсчетов сигнала
электроэнцефалограммы (ЭЭГ). Целью настоящей работы является исследование влияния учета
индивидуальной реакции пользователей на результат классификации команд моделями МО, ис-
пользуемыми при проектировании ИМК. Для этого был протестирован ряд моделей, использу-
емых ранее для реализации MI, SSVEP, P300 и иных парадигм: ATCNet, DeepConvNet, EEGNet,
EEGNetX, EEG-TCNet, MBEEG_SENet, ShallowConvNet и TCNet_Fusion. В качестве источника
данных использовались открытые наборы 12JFPM и TsinghuaBCI_Benchmark, предоставляющие
в сумме доступ к результатам проведения экспериментов на 45 испытуемых. Используя отно-
шение сигнал/шум (ОСШ) ЭЭГ сигнала как показатель выраженности реакции, для каждой
частоты фотостимуляции был определен коэффициент совместимости с испытуемым. На его
основе были составлены индивидуальные профили испытуемых, включающие по 4 значения

* Статья получена 04 марта 2025 г.

частоты, обладающих минимальным и максимальным показателем совместимости. Это позволило протестировать работу выбранных моделей в двух противоположных условиях.

Полученные в настоящем исследовании результаты показывают, что учет индивидуальной реакции оказывает положительное влияние на такие характеристики ведущих моделей МО, как точность классификации и коэффициент каппы Коэна, особенно для моделей ATCNet и EEG-TCNet. Применение парного критерия Стьюдента (t -тест) говорит о статистической значимости полученных результатов для моделей ATCNet и EEG-TCNet ($p < 0,01$), а также для моделей MBEEG_SENet и TCNet_Fusion ($p < 0,05$). Усредненные показатели главной диагонали матрицы путаницы названных выше моделей демонстрируют прирост в положительную сторону.

Ключевые слова: интерфейсы «мозг – компьютер», устойчивые визуально вызванные потенциалы, биомедицинские сигналы, электроэнцефалограмма, машинное обучение, индивидуальная реакция пользователей, отношение сигнал/шум, коэффициент совместимости частоты, точность классификации, каппа Коэна, матрица путаницы

ВВЕДЕНИЕ

Интерфейсы «мозг – компьютер» (ИМК, англ. Brain Computer Interface – BCI) как системы обеспечения связи между электронным вычислительным устройством и мозгом впервые были предложены в 1973 г. Жаком Ж. Видалем [1]. В вышеуказанной работе концепция ИМК предлагается не только как способ использования сигналов мозга для взаимодействия с компьютером, но и как новый инструмент для изучения нейрофизиологических явлений в перспективе. С течением времени эта область значительно расширилась и преобразилась благодаря новым открытиям в нейрофизиологии и медицине, а также появлению продвинутых алгоритмов анализа и обработки данных (см. обзор в работе [2]). В настоящее время ИМК были использованы в системах реабилитации с целью лечения различных неврологических заболеваний и травм. С их помощью стало возможным восстановление зрения, слуха и чувства равновесия [3], а также утраченных двигательных навыков у людей, перенесших инсульт [4]. Были реализованы проекты по управлению курсором мыши, набору текста с цифровой клавиатуры и формированию управляющих команд роботам [4, 5]. Благодаря внедрению биологической обратной связи ИМК могут быть направлены на реорганизацию коры головного мозга, выполняя тем самым восстановительную функцию [4, 6]. Всё это делает данное направление особенно важным и актуальным.

Ключевым элементом реализации ИМК является электроэнцефалограмма (ЭЭГ) – метод регистрации нейронной активности, основанный на измерении разности электрических потенциалов, возникающих в результате синхронизированной работы группы нейронов коры головного мозга. Для этого используются специальные электроды, размещающиеся на поверхности кожи головы, а также устройство усиления и регистрации потенциалов – электроэнцефалограф. Каждый электрод обозначается соответствующим названием, включающим первую букву латинского наименования области, над которой он установлен (pre-frontal – Fp, frontal – F, temporal – T, parietal – P, occipital – O, central – C и midline – Z), и номер, указывающий на сторону и расположение электрода в пределах этой области [7]. Для стандартизации расположения электродов используется международная система размещения электродов «10–20 %» (система 10–20 %) или ее расширенная версия – «10–10 %» (система 10–10 %) [7].

Эти системы определяют правила размещения электродов на основе анатомических ориентиров черепа, разделяя его на зоны с шагом 10 или 20 % от общего расстояния между ключевыми точками, что обеспечивает воспроизводимость результатов между исследователями и точную локализацию источников нейронной активности [7]. Результатом проведения регистрации нейронной активности становится дискретный многоканальный ЭЭГ-сигнал, содержащий отсчеты, взятые с фиксированной частотой (частотой дискретизации) и отражающие изменение напряжения в каждом электроде (отведении ЭЭГ сигнала) во времени. Полученные данные в дальнейшем отправляются для их обработки, анализа и интерпретации в системе ИМК.

ОСНОВНЫЕ ПАРАДИГМЫ ИМК И ИХ ОСОБЕННОСТИ

Для проектирования ИМК было предложено множество парадигм, различающихся способами воздействия на пользователя, методами обработки входных данных и принципами генерации управляющих воздействий (команд). Каждой из них характерны как определенные преимущества, так и различного рода ограничения. Наиболее известными являются парадигмы P300, MI и SSVEP.

Парадигма P300 основана на регистрации когнитивных откликов пользователя (потенциалов, связанных с событиями, англ. Event-Related Potentials – ERPs), возникающих в ответ на предъявление единичного, относительно редкого целевого стимула (визуального, слухового или соматосенсорного) [4, 7]. В рамках парадигмы предполагается усреднение множества образцов (эпох, фрагментов) ЭЭГ-сигнала во временной области, связанных с предъявлением одного и того же целевого стимула, и последующий поиск потенциала P300, возникающего спустя ~300 мс относительно начала предъявления стимула [7]. Усреднение необходимо для подавления фоновой ЭЭГ-активности и артефактов (помех) ЭЭГ-сигнала, поскольку потенциал P300 обладает весьма низкой амплитудой и отношением сигнал/шум (ОСШ, англ. Signal-To-Noise Ratio – SNR) [7]. Это негативным образом сказывается на скорости передачи информации (англ. Information Transfer Rate – ITR) в подобных ИМК. Для классификации потенциалов P300 традиционно используются разновидности линейного дискриминантного анализа (англ. Linear Discriminant Analysis – LDA) и метод опорных векторов (англ. Support Vector Machine – SVM) [7].

В основе парадигмы MI лежит распознавание десинхронизации (подавления) сенсомоторных ритмов ЭЭГ-сигнала, возникающей при мысленном воображении совершения движений (руками, ногами, языком и т. д.) без их фактического исполнения [4]. Сенсомоторный ритм сосредоточен в центральных и центрально-височных областях и в наибольшей степени выражен в отведениях C3 и C4 [8], занимая частотный диапазон от 8 до 13 Гц в спектре ЭЭГ-сигнала [4]. Для классификации сенсомоторных ритмов в настоящее время всё чаще используют модели машинного (МО, англ. Machine learning – ML) и глубокого (англ. Deep learning – DL) обучения, такие как сверточные нейронные сети (англ. Convolutional Neural Network – CNN), рекуррентные нейронные сети (англ. Recurrent Neural Network – RNN) и различные их модификации, например механизм долгой краткосрочной памяти (англ. Long short-term memory – LSTM) [8, 9]. Хотя данное направление продолжает активно развиваться, средняя точность распознавания команд в ИМК на основе парадигмы MI находится на уровне

85 %, а расширение их количества сказывается негативным образом на результатах классификации [9]. Современные решения, такие как Mamba и KSA-Mamba-PySPConv, показывают уровень точности классификации около 89,4 % и 96,76 % соответственно [10], однако им еще предстоит пройти через этапы оптимизации для повышения скорости и расширить область применения другими парадигмами ИМК. Имеются также требования к предварительному обучению пользователя для эксплуатации подобных ИМК, что может занимать длительное время [4], а для некоторых людей невозможно вовсе [8]. Для обозначения этой группы используется термин «BCI illiteracy» (ИМК-неграмотность), отражающий неспособность пользователя к формированию управляющих воздействий [11].

В основе парадигмы SSVEP лежит распознавание устойчивых визуально вызванных потенциалов (УВВП, англ. Steady-State Visual Evoked Potentials – SSVEPs), возникающих в ответ на предъявление испытуемому серии периодических визуальных раздражителей (фотостимулов или изображений) и синхронизации активности нейронов с частотой их предъявления [7, 12]. Такой вид потенциалов проявляется как серия гармонических колебаний во временной области и может быть обнаружен в частотной области на соответствующих гармониках и их целых кратных компонентах [12]. Например, при демонстрации испытуемому последовательности вспышек света с частотой 7 Гц в спектре ЭЭГ-сигнала могут быть обнаружены ярко выраженные гармоники на частотах 7, 14 и 21 Гц. В наибольшей степени потенциалы SSVEP выражены в затылочной области коры головного мозга, ответственной за обработку зрительной информации (отведения O1, O2 и Oz) [13]. В отличие от парадигмы P300, для обнаружения реакции пользователя на стимул не требуется выполнять усреднение множества эпох ЭЭГ-сигнала, так как потенциалы SSVEP обладают высоким ОСШ. Это обеспечивает более высокую скорость передачи информации (ITR) за счет сокращения времени на генерацию команд [7]. Отдельным преимуществом парадигмы SSVEP являются минимальные требования к предварительному обучению пользователя для эксплуатации ИМК [7]. Для классификации потенциалов SSVEP используются методы спектрального анализа, включая быстрое преобразование Фурье (БПФ) [7], а также такие методы, как канонический корреляционный анализ (англ. Canonical Correlation Analysis – CCA) и его модификации [14]. В последние годы для автоматического выполнения классификации команд активно исследуется использование методов машинного и глубокого обучения, например, сверточных нейронных сетей (CNN) [15, 16]. Точность классификации в подобных ИМК достигает 90...95 %, а количество распознаваемых команд зависит от числа уникальных частот стимулов, предъявляемых пользователю [17]. Современные подходы, такие как метод OS-SSVEP, комбинирующий кросс-субъектную сеть слияния в двух доменах (CSDuDoFN) и методы анализа компонент, демонстрируют перспективы классификации потенциалов SSVEP при наличии лишь одного калибровочного образца данных на стимул, что крайне важно для персонализации ИМК в условиях ограниченного набора данных [18]. Были также представлены решения, нацеленные на преодоление ограничений традиционных методов машинного обучения (низкая точность при коротких данных) и глубокого обучения (требование большого объема входных данных [13]) за счет их комбинации, такие как «eTRCA+sbCNN» [19]. В отдельных работах исследуются также возможности учета дополнительных когнитивных факторов, таких как цветовое восприятие [20], степень утомления [21], и иных показателей.

ОГРАНИЧЕНИЯ И ПРОБЛЕМЫ ИМК НА ОСНОВЕ ПАРАДИГМЫ SSVEP

Хотя ИМК на основе парадигмы SSVEP отличаются рядом преимуществ, для них характерны и некоторые нерешенные проблемы и ограничения. Так, реакция пользователей на фотостимулы крайне индивидуальна и может не только заметно отличаться между испытуемыми [7, 21], но и меняться с течением времени. Это приводит к сокращению количества потенциально возможных к выполнению команд, когда реакция пользователя на фотостимул ослабла, перестала проявляться или не наблюдалась вовсе. Серии фотостимулов могут приводить к утомлению и представляют опасность для людей, страдающих фотосенситивной эпилепсией. Некоторые пользователи (от 15 до 30 %) не обладают возможностью формировать управляющие воздействия из-за особенностей функционирования нервной системы и строения черепа (ИМК-неграмотность) [11, 22]. Имеется и ряд разногласий в научном сообществе. Так, мнения об оптимальном диапазоне частот фотостимуляции значительно отличаются среди исследователей, охватывая весьма широкий, отличающийся друг от друга набор значений [12, 23, 24]. Большинство исследований направлено на поиск единого априорно-оптимального диапазона частот, в то время как проблема их индивидуального подбора остается недостаточно изученной [12, 21, 24]. При этом отмечается, что переход в сторону индивидуального учета реакции на фотостимулы стал бы важным шагом в сторону совершенствования данного вида ИМК [11, 24]. Учет этой особенности и поиск решения для адаптации ИМК к пользователю станет важным шагом к их практическому применению в повседневной жизни, за пределами лабораторий.

ЦЕЛЬ И ЗАДАЧИ ИССЛЕДОВАНИЯ

Подводя итог вышесказанному, ввиду актуальности проблемы персонализации ИМК в настоящей работе рассматривается, как учет индивидуальной реакции пользователей способен повлиять на результат классификации фотостимулов в ИМК, основанных на парадигме SSVEP и моделях МО. Основная гипотеза исследования поставлена следующим образом: учет индивидуальной реакции пользователей при выборе частот фотостимуляции статистически значимо улучшает точность классификации и согласованность результатов моделей машинного обучения, архитектура которых адаптирована для работы в рамках парадигмы SSVEP.

1. ВХОДНЫЕ ДАННЫЕ И ИХ ОБРАБОТКА

1.1. НАБОРЫ ДАННЫХ

Для проведения настоящего исследования были использованы два открытых набора данных (датасета). Первый набор был получен в ходе работы [14], посвященной сравнительному анализу производительности методов канонического корреляционного анализа для классификации потенциалов SSVEP. В настоящем исследовании он будет именоваться как 12JFPM. Второй набор

данных представлен в качестве эталонного датасета для тестирования методов классификации потенциалов SSVEP [17]. В настоящем исследовании он именуется как TsinghuaBCI_Benchmark. Каждый из них содержит записи нейронной активности (ЭЭГ-сигналы), полученные от группы испытуемых в результате проведения эксперимента по предъявлению визуальных раздражителей заданной частоты (фотостимулов). Целью их предъявления был вызов и регистрация устойчивых визуально вызванных потенциалов (SSVEP). В рамках эксперимента каждый испытуемый выполнил ряд сессий по концентрации на используемых в наборе данных фотостимулах. В пределах отдельно взятой сессии испытуемому последовательно демонстрировались фотостимулы, выбранные в случайном порядке, до тех пор, пока не будет получен фрагмент реакции на каждый из них. Подробная информация об условиях проведения экспериментов и дополнительные технические характеристики для каждого набора данных приведены в табл. 1.

Таблица 1

Table 1

Условия проведения экспериментов и технические характеристики

Experimental conditions and specifications

Набор данных	12JFPM	TsinghuaBCI_Benchmark
Количество испытуемых	10	35, из которых 27 без опыта работы с ИМК; 8 имеют опыт работы с ИМК
Количество сессий эксперимента	15	6
Количество уникальных частот фотостимуляции	12	40
Используемый диапазон частот для генерации фотостимулов, Гц	9,25...14,75 (шаг 0,5)	8,0...15,8 (шаг 0,2)
Продолжительность регистрации реакции на фотостимул, с	4,15, из которых 0,15 – установка фотостимула; 4,00 – фотостимуляция	6,00, из которых 0,5 – предварительная подсказка; 5,0 – фотостимуляция; 0,5 – отдых
Частота дискретизации сигнала, Гц	256	250
Устройство отображения фотостимулов	Монитор LCD	Дисплей LCD
Имитация устройства ввода	Панель ввода	Цифровая клавиатура
Набор символов	10 цифр + 2 спец. знака	26 букв + 10 цифр + + 4 спец. знака
Маркировка фотостимулов	Присутствует	Присутствует
Система размещения электродов	10–10 %	10–10 %
Общее количество электродов и их тип	8 хлорсеребряных электродов, расположенных в затылочной области	64 хлорсеребряных электрода

1.2. ПРЕДВАРИТЕЛЬНАЯ ОБРАБОТКА ДАННЫХ

Перед дальнейшей работой с полученными данными, в рамках настоящей статьи выполняется этап их предварительной обработки. Во-первых, поскольку потенциалы SSVEP наиболее выражены в затылочных отведениях (O1, O2 и Oz [13]), было выполнено сокращение их списка до четырех близлежащих к данной области электродов. Для набора 12JFPM их список был сокращен до отведений O1, O2, POz и Pz, а для набора TsinghuaBCI_Benchmark – до отведений O1, O2, PO3 и PO4. Это исключит из анализа заведомо не обладающие полезной информацией данные и снизит объем вычислений. Известно также, что латеральная затылочная и задняя височная области могут содержать информацию о сосредоточении на буквах и их мысленном произнесении [25]. Этот факт также повлиял на принятие решения о сокращении списка отведений, поскольку источники фотостимулов в выбранных наборах данных обладали вспомогательными подписями. Такая нейронная активность не имеет прямого отношения к потенциалам SSVEP, но может повлиять на результат классификации.

Во-вторых, для исключения низкочастотных артефактов (электроокулограмма, кожно-гальваническая реакция, дрейф изолинии), а также помех от сети электропитания был использован цифровой фильтр Баттерворта 8-го порядка с граничными частотами 4 и 50 Гц. Путем выполнения операции дискретной свертки импульсной характеристики фильтра с зарегистрированными фрагментами ЭЭГ-сигнала в них ослабляются частотные компоненты, выходящие за пределы полосы пропускания (ПП) фильтра, сохраняя при этом полезные компоненты сигнала. Этот момент очень важен, поскольку большинство артефактов значительно превосходят полезный ЭЭГ-сигнал по амплитуде, что негативно сказывается на качестве сигнала и работе с ним. Выбор фильтра Баттерворта обусловлен его максимально плоской амплитудно-частотной характеристикой (АЧХ) в области ПП, что минимизирует искажение полезного сигнала.

В-третьих, после фильтрации данных производилось усечение временных рядов: удалялись интервалы, соответствующие периодам подготовки испытуемых к концентрации на фотостимулах. Это позволило исключить данные, связанные с переходными процессами (в том числе внесенными в результате работы цифрового фильтра на предыдущем этапе), и сфокусироваться на непосредственном анализе реакций на фотостимулы.

В окончательном виде прошедшие этап предварительной обработки и подготовленные к дальнейшей работе с моделями МО данные каждого испытуемого были представлены многомерным сигналом в следующем формате:

$$EEG[t][f][c][n], \quad (1)$$

где t (*trial*) – номер сессии эксперимента; f (*frequency*) – номер частоты фотостимула; c (*channel*) – номер отведения ЭЭГ сигнала; n – номер дискретного отсчета.

1.3. МЕТОДИКА ОЦЕНКИ СОВМЕСТИМОСТИ ЧАСТОТЫ

Основная цель анализа данных в настоящем исследовании заключается в определении того, насколько критичным является момент индивидуального подбора частоты фотостимуляции при проектировании ИМК на основе

парадигмы SSVEP и моделей МО. В частности, актуальность этой проблемы обусловлена тем, что, несмотря на активное развитие новых архитектур моделей, вопрос учета индивидуальных особенностей реакции мозга на стимулы поднимается не так часто. Это создает риск занижения действительного потенциала моделей при тестировании: если данные для их обучения собирались без учета специфики реакции конкретного испытуемого, результаты могут оказаться некорректными. Для проверки этой гипотезы необходимо протестировать существующие модели в двух противоположных условиях: с учетом полной несовместимости испытуемого с используемыми частотами фотостимуляции и абсолютной (или максимально близкой к тому) совместимостью, что позволит выявить степень влияния данного фактора.

Как было отмечено ранее, концентрация внимания на периодическом визуальном стимуле проявляется в ЭЭГ-сигнале в виде гармонических компонент, соответствующих частоте мерцания. Однако в силу индивидуальных особенностей испытуемого не все из используемых частот способны вызвать в достаточной степени выраженную реакцию – потенциал SSVEP. В таком случае он может проявляться нестабильно, практически не выделяясь относительно фоновой ЭЭГ-активности, либо отсутствовать вовсе. Это соответствующим образом сказывается и на ОСШ, если рассматривать в качестве полезной составляющей целевую частоту фотостимуляции. Для дальнейшего учета данного явления в рамках настоящей работы вводится коэффициент совместимости частоты фотостимуляции с испытуемым. Данный коэффициент основан на анализе поведения ОСШ в процессе предъявления фотостимула и определяется следующим образом.

1. Выполняется загрузка, предварительная обработка и приведение данных ЭЭГ испытуемого к виду (1), как было описано в предыдущем разделе.

2. Из полученного многомерного сигнала от всех сессий $[t]$ испытуемого извлекаются эпохи ЭЭГ сигнала $[c][n]$, соответствующие периоду фотостимуляции с заданной частотой $[f]$.

3. В каждой сессии $[t]$ и отведении $[c]$ выполняется разбиение данных ЭЭГ на набор окон из 512 отсчетов каждое (~ 2 секунды) и величиной шага в 64 отсчета ($\sim 0,25$ секунды) между окнами. Константы взяты с учетом продолжительности сессий и обеспечения достаточного спектрального разрешения.

4. Для каждого из полученных окон выполняется вычисление БПФ, получение одностороннего спектра мощности и вычисление на его основе ОСШ для каждого значения частоты в отдельности (рассматривая ее как полезный сигнал).

5. Для каждого отведения $[c]$ выполняется подсчет количества окон от всех сессий $[t]$, где пик ОСШ приходится на близлежащую к частоте фотостимуляции $[f]$ гармонику.

6. Максимальное из полученных показателей используется для вычисления процента окон с наличием реакции на основе их общего количества для одного отведения.

7. Полученное значение принимается как коэффициент совместимости частоты фотостимуляции $[f]$ с испытуемым (аналогичные расчеты выполняются для всех остальных частот).

Таким образом, значения полученного коэффициента будут представлять индивидуальный численный показатель, отражающий степень совместимости

каждой частоты фотостимуляции с испытуемым в интервале от нуля до 100 %. Близкие к 100 % значения коэффициента будут указывать на максимальный уровень совместимости частоты, гарантируя наличие выраженной и стабильной реакции у испытуемого, и наоборот. Это позволит выделить для каждого испытуемого подмножества частот фотостимуляции, обладающих максимальным и минимальным уровнем совместимости, после чего проверить работу моделей в задаче классификации соответствующих потенциалов SSVEP. Стоит отметить, что такой подход имеет определенные ограничения, поскольку ориентируется на максимальный показатель ОСШ во всем частотном диапазоне. Это является приемлемым для анализа низкочастотных потенциалов SSVEP, используемых в выбранных наборах данных, но не будет подходить для потенциалов SSVEP высокой частоты (с ее увеличением снижается амплитуда потенциала SSVEP и, следовательно, ОСШ) [21]. Для более тонкой работы, в условиях фотостимуляции на высокой частоте, необходимо иметь данные о фоновой ЭЭГ-активности испытуемых, зарегистрированной вне периода предъявления фотостимулов, что не было выполнено в используемых наборах данных.

2. МОДЕЛИ МАШИННОГО ОБУЧЕНИЯ И ПАРАМЕТРЫ КЛАССИФИКАЦИИ

2.1. АРХИТЕКТУРЫ МОДЕЛЕЙ И ИХ ОСОБЕННОСТИ

Для более глубокого понимания влияния индивидуальной реакции пользователей на модели машинного обучения был проведен обзор наиболее известных из них. Они были выбраны на основе распространенности и частоты упоминания в различных исследованиях, затрагивающих не только SSVEP, но и другие виды парадигм. Хотя в настоящее время количество новых моделей и их модификаций непрерывно растет, большинству из них еще предстоит внедриться в повседневную практику и расширить круг охватываемых парадигм для возможности сопоставления полученных результатов с другими работами. Всего было выбрано 8 моделей.

1. ATCNet – модель на основе временной сверточной сети и блока внимания. Исследователи из Саудовской Аравии в работе [9] предложили модель для классификации воображения движений в рамках парадигмы MI, где превзошла все перечисленные далее модели. Авторами настоящей статьи не было найдено исследований, посвященных ее применению в рамках парадигмы SSVEP.

2. DeepConvNet – модель, представленная в работе [26] для задачи декодирования сигналов ЭЭГ. Используется во множестве исследований для работы в рамках парадигм MI, P300 и SSVEP [8, 9, 13, 15, 26–28]. В работе [28] протестирована на наборе TsinghuaBCI_Benchmark, достигнув точности классификации $74,55 \pm 6,74$ %.

3. EEGNet – сверточная нейронная сеть, представленная в работе [16] и использованная в рамках парадигм P300, ERN, MRCP, SMR [16], SSVEP [15] и MI [9, 13]. Была протестирована на наборе TsinghuaBCI_Benchmark в исследовании [28], достигнув точности классификации $76,18 \pm 7,65$ %.

4. EEGNeX – нейронная сеть на основе свертки, предложенная для анализа ЭЭГ-сигналов в работе [29] и протестированная в рамках парадигм ERP, MI, SMR и ERN. В исследовании [13] используется для работы с парадигмами MI и P300, демонстрируя крайне низкую точность классификации (44,03 % и 58,65 % соответственно).

5. EEG-TCNet – временная сверточная сеть, особенностью которой является малое количество параметров для обучения. Была представлена в работе [30] и протестирована в рамках парадигмы MI. В работе [13] тестируется на парадигмах MI и P300, демонстрируя средний уровень точности классификации 37,98 % (с единичным пиком до 71,11 %) и 71,19 % соответственно.

6. MBEEG_SENet – сверточная нейронная сеть, представленная как многоотраслевая версия EEGNet с блоками сжатия и возбуждения для работы в рамках парадигмы MI [31]. Была протестирована на парадигмах MI, SSVEP и ERN в [32], достигнув точности классификации $64,58 \pm 6,07$ %, $56,45 \pm 7,27$ % и $75,46 \pm 2,34$ % соответственно.

7. ShallowConvNet – уменьшенная версия модели DeepConvNet, представленная в работе [33]. Протестирована в рамках парадигмы SSVEP в [15], достигнув точности классификации на уровне 68 %. В [13] используется в рамках парадигм MI и P300. Была также использована в [28] на наборе данных TsinghuaBCI_Benchmark, достигнув точности классификации $60,82 \pm 6,40$ %.

8. TCNet_Fusion – модель сверточной нейронной сети на основе фиксированных гиперпараметров. Использует временные сверточные сети, разделяемую свертку, глубинную свертку и слияние слоев. Предложена в работе [34] и протестирована в рамках парадигмы MI. В [32] была использована в рамках парадигм MI, SSVEP и ERN, достигнув точности классификации $56,52 \pm 3,07$ %, $45,00 \pm 6,45$ % и $70,46 \pm 2,94$ % соответственно.

2.2. ПАРАМЕТРЫ ОБУЧЕНИЯ МОДЕЛЕЙ

Исследование проводилось с использованием графического процессора (ГП) NVIDIA GeForce RTX 3070 Ti, обладающего видеопамью 8192 МБ и TensorFlow-фреймворком версии 2.18 для python 3.9. Версия драйвера ГП – 570.124.04 для ОС на базе ядра Linux. В качестве центрального процессора (ЦП) использован Intel Core i9-12900KF. Объем оперативной памяти составляет 32 Гб с тактовой частотой 6000 МГц. Для обучения моделей в настоящем исследовании использовались следующие параметры, учитывающие опыт предыдущих работ [9, 13, 29] и поведение кривых обучения моделей при первоначальном тестировании на 1000 эпохах обучения (график функции валидационных потерь не демонстрировал существенного уменьшения после 350–450 эпох, график точности классификации не демонстрировал существенных изменений после 500 эпох):

- batch size = 64 – размер партии данных, использующихся одновременно в рамках итерации обновления весов модели;
- epochs = 500 – количество полных проходов (эпох обучения) по всему набору данных на этапе обучения модели;
- learning rate = 0,001 – начальный коэффициент скорости обучения, определяющий степень изменения весов модели на этапе оптимизации.

В качестве функции потерь использовалась кросс-энтропия между истинными и предсказанными вероятностями классов данных. В роли оптимизатора выбран Adam с параметром learning rate = 0,001 [9, 13]. В роли метрики для оценки производительности моделей выбрана точность классификации (accuracy) [9]. Для контроля процесса обучения установлены обратные вызовы со следующими параметрами:

- ModelCheckpoint – для сохранения весов модели в процессе обучения при каждом уменьшении валидационной потери (модифицирован для возможности сохранять номер эпохи, на которой произошло последнее сохранение);
- ReduceLROnPlateau – для уменьшения скорости обучения на 10 %, когда на протяжении 20 эпох не наблюдается улучшение валидационной потери (минимально допустимая скорость обучения установлена в 0,0001 [9]);
- GPUMetricsCallback – авторский коллбек на основе runvml для сохранения статистики об использовании ГП в процессе обучения.

Каждая из названных выше моделей с установленными параметрами обучения должна быть протестирована в задаче классификации фотостимулов в двух противоположных условиях. Для этого используется введенный в настоящей работе коэффициент совместимости частоты. С его помощью для каждого испытуемого формируется два индивидуальных профиля (далее – профиль № 1 и профиль № 2), включающих персонализированные комбинации частот стимуляции, обладающих минимальным и максимальным коэффициентом совместимости соответственно. Учитывая количество уникальных частот фотостимуляции в наборе 12JFPM (см. табл. 1) и требование к формированию наиболее и наименее совместимых с испытуемым комбинаций, было решено оставить 4 классифицируемые команды. Это позволит получить непересекающиеся между собой наборы частот, а также разграничить их друг от друга.

2.3. МЕТОДЫ ВАЛИДАЦИИ

Для оценки работы моделей на этапах их обучения и тестирования были выбраны три взаимодополняющие метрики: точность классификации, коэффициент каппы Коэна и матрица путаницы [9]. Точность классификации (accuracy) выбрана как интуитивно понятная метрика, отражающая долю правильно классифицированных команд. Для ИМК критично минимизировать уровень ошибок, так как они напрямую влияют на надежность управления устройствами. Точность классификации (2) вычисляется как среднее арифметическое отношений правильно предсказанных образцов к их общему количеству для каждого класса (команды):

$$ACC = \frac{\sum_{i=1}^n TP_i / I_i}{n}, \quad (2)$$

где i – номер класса (команды); TP_i – количество правильно предсказанных образцов класса i ; I_i – общее количество образцов класса i ; n – количество классов.

Коэффициент каппы Коэна (коэффициент межэкспертного согласия) – метрика, используемая для оценки согласованности классификаций, учитывая возможность случайного совпадения (3). Ее значения, близкие к единице, указывают на высокую согласованность, а близкие к нулю – на уровень согласия, сравнимый со случайным [9]. Учет этой метрики позволяет дополнить сведения, полученные в результате анализа показателя точности, поскольку последний дает лишь общее представление об отношении правильно классифицированных образцов данных к их общему числу, но при этом не учитывает ложноположительные и ложноотрицательные результаты [9]. Коэффициент каппы Коэна, с другой стороны, позволяет учесть уровень согласия между предсказаниями модели и реальной принадлежностью данных к классам, корректируя результаты на случайное совпадение. Это особенно важно в условиях искажения данных различного рода шумом, что характерно для биомедицинских сигналов [9]:

$$k_score = \frac{1}{n} \sum_{a=1}^n \frac{P_a - P_e}{1 - P_e}, \quad (3)$$

где n – количество классов (команд); P_a – фактический процент согласия; P_e – ожидаемый процент случайного согласия.

В дополнение к двум предыдущим метрикам по окончании тестирования каждой модели выполняется построение матриц путаницы (confusion matrix). Матрицы путаницы позволяют анализировать распределение ошибок между классами, что важно для выявления систематических проблем в классификации (например, частот, чаще других вызывающих ошибки классификации) [9]. Совместное использование этих метрик обеспечит комплексную оценку: точность и каппа Коэна дают общее представление о результатах классификации, а матрица путаницы объясняет их за счет анализа ошибок на уровне отдельных классов.

При обучении моделей на наборе 12JFPM используются первые 13 его сессий, а на наборе TsinghuaBCI_Benchmark – первые 5. Как и при вычислении коэффициента совместимости, данные каждой сессии разбиваются на набор окон в 512 отсчетов с величиной шага 64 отсчета. Эти константы выбраны исходя из опыта предыдущих исследований [9, 13, 29]. Полученные фрагменты данных стандартизируются путем приведения к нулевому среднему значению и единичной дисперсии отдельно по каждому каналу, а затем случайным образом разбиваются на обучающую и валидационную выборки (80 % используются для обучения, оставшиеся 20 % – для тестирования). Каждая модель получает 5 попыток для обучения. После завершения очередной попытки вычисляются выбранные метрики. Тестирование моделей на окончательных весах выполняется на оставшихся данных сессий, не участвующих в процессе обучения, с аналогичными этапами разбиения и нормализации. По результатам тестирования для каждой модели и участника вычисляются точность классификации и коэффициент каппы Коэна, а также строится усредненная матрица путаницы по всем испытаниям.


Если выдвинутая в рамках статьи гипотеза верна, то переход к работе моделей на фотостимулах профиля № 2 улучшит точность классификации, коэффициент каппы Коэна и показатели матриц путаницы. Ожидается также

повышение средних значений и снижение стандартного отклонения для первых двух метрик. Это будет указывать на достижение более высоких и стабильных показателей среди испытуемых.

3. РЕЗУЛЬТАТЫ

3.1. ИНДИВИДУАЛЬНАЯ ВАРИАБЕЛЬНОСТЬ РЕАКЦИИ ИСПЫТУЕМЫХ НА ФОТОСТИМУЛЫ

Для каждого участника эксперимента было сформировано два индивидуальных профиля из четырех частот фотостимуляции. На рисунке представлены усредненные показатели коэффициента совместимости полученных профилей. Набор TsinghuaBCI_Benchmark был разделен на группу опытных (TsinghuaBCI_EX) и неопытных (TsinghuaBCI_NAIVE) пользователей согласно описанию набора [17].



Усредненный показатель коэффициента совместимости частоты фотостимуляции индивидуальных профилей испытуемых

Averaged compatibility coefficient of photostimulation frequency of subjects' individual profiles

Из представленных графиков видно, что, хотя для формирования профиля № 2 используются частоты фотостимуляции, вызывающие наиболее выраженный потенциал SSVEP, средний показатель коэффициента совместимости не всегда достигает максимума. Это связано с двумя причинами. Во-первых, проявляется индивидуальная вариабельность: не все частоты фотостимуляции вызывают достаточно выраженную реакцию у испытуемого. Во-вторых, некоторое занижение результатов могло быть вызвано способом вычисления

коэффициента, недостаток которого был описан выше. С учетом работы в условиях низкочастотных потенциалов SSVEP и ручного контроля показателя ОСШ для участников со спорными показателями такой исход оценивается как маловероятный, но не может быть полностью исключен. Отдельно стоит упомянуть испытуемых № 4 и № 8 набора 12JFPM. Их усредненные показатели достигают высоких значений не только во втором, но и в первом индивидуальном профиле. Это указывает на высокий уровень совместимости испытуемых с используемым в эксперименте диапазоном частот фотостимуляции. Кроме того, подчеркивается относительная редкость подобных случаев: из 45 испытуемых лишь у двоих наблюдается подобный эффект.

3.2. АНАЛИЗ МЕТРИК КЛАССИФИКАЦИИ

После завершения обучения и тестирования моделей для каждого из 45 испытуемых были вычислены соответствующие индивидуальным профилям пары метрик точности классификации и коэффициента каппы Коэна. Поскольку имеющиеся результаты отражают ситуацию «до – после» и получены для одних и тех же испытуемых (единая группа), для отражения статистической значимости результатов была вычислена вероятность, соответствующая парному критерию Стьюдента (t -тест). Для отражения статистических показателей по всем испытуемым для каждой модели и индивидуального профиля были вычислены средние значения метрик, а также стандартное отклонение их разностей между профилями. В табл. 2 содержатся итоговые показатели для точности классификации, а в табл. 3 – для коэффициента каппы Коэна.

Таблица 2

Table 2

Усредненная точность классификации фотостимулов моделями МО

Averaged photostimuli classification accuracy for ML models

Модель МО	Профиль № 1 сред. (ст. откл.), %	Профиль № 2 сред. (ст. откл.), %	Разница сред. (ст. откл.), ‰	t -тест (p -value)
ATCNet	91,44 (11,50)	95,83 (8,63)	+4,40 (10,45)	0,007
DeepConvNet	75,35 (17,63)	74,70 (20,14)	−0,65 (19,98)	0,829
EEGNet	86,72 (15,69)	90,47 (14,81)	+3,75 (14,33)	0,086
EEGNeX	55,07 (16,60)	50,98 (18,86)	−4,09 (22,89)	0,237
EEG-TCNet	86,48 (14,13)	94,59 (9,99)	+8,11 (12,34)	0,000
MBEEG_SENet	85,40 (15,46)	90,30 (13,40)	+4,90 (14,17)	0,025
ShallowConvNet	75,22 (22,04)	78,34 (20,88)	+3,13 (22,12)	0,348
TCNet_Fusion	83,65 (17,18)	88,68 (15,64)	+5,04 (16,22)	0,043

Таблица 3

Table 3

Усредненный коэффициент каппы Коэна для моделей МО

Averaged Cohen's kappa coefficient of ML models

Модель МО	Профиль № 1 сред. (ст. откл.)	Профиль № 2 сред. (ст. откл.)	Разница сред. (ст. откл.)	t-тест (p-value)
ATCNet	0,89 (0,15)	0,94 (0,12)	+0,06 (0,14)	0,007
DeepConvNet	0,67 (0,24)	0,66 (0,27)	-0,01 (0,27)	0,831
EEGNet	0,82 (0,21)	0,87 (0,20)	+0,05 (0,19)	0,086
EEGNeX	0,40 (0,22)	0,35 (0,25)	-0,05 (0,31)	0,237
EEG-TCNet	0,82 (0,19)	0,93 (0,13)	+0,11 (0,16)	0,000
MBEEG_SENet	0,81 (0,21)	0,87 (0,18)	+0,07 (0,19)	0,025
ShallowConvNet	0,67 (0,29)	0,71 (0,28)	+0,04 (0,29)	0,348
TCNet_Fusion	0,78 (0,23)	0,85 (0,21)	+0,07 (0,22)	0,043

Анализ полученных данных показывает, что переход от профиля № 1 к профилю № 2 в наибольшей степени оказал влияние на такие модели МО, как EEG-TCNet и ATCNet, улучшив их метрики. Наилучшие результаты по приросту точности классификации и коэффициента каппы Коэна получены для модели EEG-TCNet, что позволило ей достигнуть уровня ATCNet при классификации потенциалов SSVEP профиля № 2. Хотя показатели модели ATCNet достаточно высоки и на профиле № 1, переход к профилю № 2 также позволил их улучшить. Все эти изменения свидетельствуют о повышении точности и уровня доверия к результатам моделей, что подтверждается высокой статистической значимостью ($p < 0,01$), особенно для модели EEG-TCNet.

Модели MBEEG_SENet и TCNet_Fusion также показали статистически значимые улучшения метрик ($p < 0,05$), хотя их результаты остались ниже результатов двух предыдущих моделей и не достигли уровня ATCNet при ее работе на профиле № 1. Это дополнительно подчеркивает превосходство архитектуры последней модели, что согласуется с исследованием [9], где она также продемонстрировала лучшие результаты.

Оставшиеся модели не демонстрируют статистически значимых изменений, а их метрики остаются на достаточно низком уровне и имеют достаточно большой разброс показателей. Полученные результаты указывают не столько на отсутствие разницы при классификации потенциалов SSVEP в рассмотренных условиях, сколько на непригодность архитектуры моделей для работы в данной задаче.

В табл. 4 приведены усредненные показатели главной диагонали матриц путаницы, построенных по результату тестирования моделей на индивидуальных профилях № 1 и № 2. Значения главной диагонали напрямую коррелируют с точностью классификации, так как отражают долю верных предсказаний для каждого класса. Рост этих значений при переходе к профилю № 2 будет подтверждать улучшение общей точности классификации и каппы Коэна, поскольку соответствующее уменьшение элементов матрицы вне главной диагонали означает снижение доли ошибок классификации.

Таблица 4

Table 4

Показатели главной диагонали матрицы путаницы моделей при работе с профилями № 1 и № 2

The main diagonal values of the confusion matrix for the models when working with profiles No. 1 and No. 2

Модель МО	№ профиля	Класс 1	Класс 2	Класс 3	Класс 4	Мин.	Макс.	Сред.
ATCNet	1	0,89	0,93	0,94	0,86	0,86	0,94	0,91
	2	0,95	0,94	0,97	0,98	0,94	0,98	0,96
DeepConvNet	1	0,74	0,73	0,77	0,77	0,73	0,77	0,75
	2	0,74	0,71	0,75	0,78	0,71	0,78	0,75
EEGNet	1	0,86	0,88	0,92	0,80	0,80	0,92	0,87
	2	0,88	0,91	0,90	0,92	0,88	0,92	0,90
EEGNetX	1	0,56	0,51	0,53	0,59	0,51	0,59	0,54
	2	0,52	0,49	0,52	0,51	0,49	0,52	0,51
EEG-TCNet	1	0,86	0,89	0,86	0,80	0,80	0,89	0,85
	2	0,95	0,94	0,96	0,94	0,94	0,96	0,95
MBEEG_SENet	1	0,84	0,85	0,90	0,80	0,80	0,90	0,85
	2	0,88	0,92	0,89	0,93	0,88	0,93	0,90
ShallowConvNet	1	0,79	0,76	0,77	0,69	0,69	0,79	0,75
	2	0,80	0,77	0,73	0,84	0,73	0,84	0,78
TCNet_Fusion	1	0,83	0,85	0,89	0,75	0,75	0,89	0,83
	2	0,87	0,84	0,91	0,93	0,84	0,93	0,89

Полученные данные показывают, что модель ATCNet достигает лучших результатов по минимальному, максимальному и среднему показателю вероятности верной классификации после перехода к профилю № 2. Следующей оказалась модель EEG-TCNet, демонстрируя наибольший уровень прироста данных характеристик. Как и в случае анализа двух предыдущих метрик, переход к профилю № 2 оказывает положительное влияние на обе модели.

Улучшение показателей наблюдается и для моделей MBEEG_SENet и TCNet_Fusion (особенно минимальных значений). Несмотря на то что эти модели всё ещё уступают ATCNet, полученные результаты свидетельствуют о повышении их надежности и точности в классификации потенциалов SSVEP.

Модели ShallowConvNet, DeepConvNet и EEGNetX по-прежнему показывают низкие показатели, что нельзя назвать приемлемым результатом для их применения в практике.

3.3. АНАЛИЗ ПОТРЕБЛЕНИЯ РЕСУРСОВ

Для практического применения моделей МО в системах ИМК крайне важен учет их требований к вычислительным ресурсам оборудования и скорости работы. В табл. 5 представлены сводные данные об общем количестве параметров моделей, статистике использования ГП в процессе обучения, номере эпохи, на которой были достигнуты лучшие веса по критерию точности классификации, а также затраченном моделями времени на этапах обучения и тестирования. Все данные, кроме количества параметров модели, представляют собой усредненные значения, полученные по завершении каждой полной итерации (попытки) обучения/тестирования модели.

Таблица 5

Table 5

Вычислительные затраты и временные показатели моделей МО**Computational costs and time metrics of ML models**

Характеристика модели	ATCNet	Deep ConvNet	EEGNet	EEGNeX	EEG-TCNet	MBEEG_SENet	Shallow ConvNet	TCNet_Fusion
Число параметров	114 596	379 154	1764	53 252	3984	7426	12 084	12 832
Загрузка ГП, %	24,10	21,90	14,27	33,90	14,43	34,80	11,83	29,87
Использование памяти ГП, МБ	6635,67	6634,38	6638,32	6650,50	6646,93	6658,25	6659,50	6651,67
Номер лучшей эпохи, профиль № 1 (макс. точность)	256	255	362	133	362	285	264	293
Номер лучшей эпохи, профиль № 2 (макс. точность)	248	279	330	167	388	270	195	287
Время обучения, мин	1,55	0,58	0,61	0,73	0,75	1,04	0,53	0,84
Время тестирования, с	0,31	0,09	0,07	0,10	0,11	0,13	0,07	0,11

Анализ вычислительных затрат позволил сделать следующие выводы. Модель ATCNet, демонстрирующая наилучшие метрики (табл. 2–4), обладает значительным числом параметров (табл. 5) по сравнению с аналогичным показателем для EEG-TCNet (отличие в 28 раз). Однако, несмотря на меньшую архитектурную сложность, EEG-TCNet показала сопоставимую эффективность при работе с профилем № 2 (табл. 2–4), что подчеркивает важность оптимизации архитектуры. Примечательно, что DeepConvNet, имея почти в 3,3 раза больше параметров, уступает ATCNet по всем показателям метрик, что подтверждает отсутствие прямой зависимости между количеством параметров и качеством классификации.

Время обучения моделей варьируется от 0,53 (ShallowConvNet) до 1,55 минуты (ATCNet), при этом ATCNet требует больше вычислительных ресурсов (24,10 % загрузки ГП против 14,43 % у EEG-TCNet). Однако высокая скорость тестирования (0,31 секунды для ATCNet и 0,11 секунды для EEG-TCNet) делает обе модели пригодными для систем реального времени. Анализ номеров эпох с лучшими весами моделей по критерию точности классификации не выявил строгой зависимости от типа профиля.

Использование памяти ГП оставалось практически неизменным для всех моделей, что, вероятно, обусловлено особенностями выделения памяти в TensorFlow при фиксированном размере входных данных, а не используемой моделью. Частота графического процессора и видеопамати (не представлены в табл. 5) во всех случаях достигали значений 1830 МГц и 19 002 МГц, что соответствует спецификациям используемой видеокарты при ее работе в режиме GPU Boost.

ЗАКЛЮЧЕНИЕ

В рамках проведенной работы была исследована такая важная проблема, как индивидуальная вариабельность реакции пользователей ИМК на фотостимулы, а также изучено ее влияние на модели машинного обучения. Эта проблема особенно актуальна для парадигмы SSVEP, являющейся одной из основных парадигм проектирования и разработки ИМК. Несмотря на активное развитие технологии, ее практическое применение всё еще ограничено лабораторными условиями. Учет индивидуальных особенностей пользователей может стать важным шагом к повышению точности и надежности таких систем, что откроет новые возможности для их внедрения в повседневную жизнь.

Был предложен алгоритм оценки совместимости частоты фотостимуляции с пользователем, использующий отношение сигнал/шум как показатель выраженности реакции на стимул. С его помощью были составлены пары индивидуальных профилей для 45 участников открытых наборов данных 12JFPM и TsinghuaBCI_Benchmark. Первый индивидуальный профиль включал 4 частоты фотостимуляции с наименьшим коэффициентом совместимости, а второй – такое же количество частот с наивысшим коэффициентом совместимости. Хотя предложенный способ оценки показал себя в достаточной степени пригодным для работы с выбранными наборами данных в условиях потенциалов SSVEP низкой и средней частоты, его использование для оценки фотостимулов частот 30 Гц и выше ограничено в силу уменьшения ОСШ потенциалов SSVEP с увеличением частоты стимуляции. Это требует введения альтернативного, более тонкого метода анализа, учитывающего фоновую ЭЭГ-активность (не представлена в используемых наборах данных), что даст возможность анализа реакций на всем частотном диапазоне.

Используя наиболее известные в этой области модели МО, было изучено их поведение при классификации потенциалов SSVEP, относящихся к двум противоположным индивидуальным профилям. Всего в рамках работы было задействовано 8 моделей, используемых ранее при реализации различных парадигм ИМК: ATCNet, DeepConvNet, EEGNet, EEGNetX, EEG-TCNet, MBEEG_SENet, ShallowConv и NetTCNet_Fusion. В качестве метрик оценки производительности моделей использовались точность классификации и коэффициент каппы Коэна. По результатам тестирования было выполнено построение усредненных матриц путаницы для каждой из них. Была выдвинута гипотеза о том, что обучение моделей на втором индивидуальном профиле положительно скажется на выбранных метриках. Статистическая значимость результатов была проверена с помощью парного критерия Стьюдента (t -тест).

По результатам обучения и тестирования моделей были получены оценки их метрик в двух противоположных условиях. Так, согласно данным табл. 2 и 3, статистически значимое улучшение демонстрируют модели ATCNet (точность +4,40 ‰; $p < 0,01$; каппа +0,06; $p < 0,01$) и EEG-TCNet (точность +8,11 ‰; $p < 0,01$; каппа +0,11; $p < 0,01$) при обучении на профиле №2. Эти модели достигли максимальных значений как по точности (95,83 % и 94,59% соответственно, табл. 2), так и по согласованности классификации (0,94 и 0,93 соответственно, табл. 3). Соответствующие улучшения также наблюдаются и в матрицах путаницы: средние значения главной диагонали для ATCNet выросли с 0,91 до 0,96, а для EEG-TCNet – с 0,85 до 0,95 (табл. 4), что указывает на снижение ошибок классификации.

Модели MBEEG_SENet и TCNet_Fusion демонстрируют умеренный, статистически значимый ($p < 0,05$) прирост точности (+4,90 ‰ и +5,04 ‰ соответственно, табл. 2) и каппы Коэна (+0,07 в обоих случаях, табл. 3) при переходе на профиль № 2, однако их абсолютные показатели остались ниже, чем у ATCNet и EEG-TCNet, обученных на этом же профиле. Это указывает на то, что их архитектура менее адаптирована для классификации SSVEP-потенциалов, несмотря на положительный эффект от индивидуального подбора частот. Тем не менее, согласно показателям матриц путаницы моделей (табл. 4), их минимальные, максимальные и усредненные по главной диагонали значения получили улучшения, позволяющие им превзойти модель EEG-TCNet, обученную на профиле № 1. Хотя модель EEGNet также демонстрирует положительный прирост метрик, значимость этих изменений не была подтверждена ($p > 0,05$).

Модели DeepConvNet, ShallowConvNet и EEGNet не продемонстрировали значимых улучшений метрик при классификации потенциалов SSVEP (табл. 2–4), что подтверждается как отсутствием статистической значимости этих изменений ($p > 0,05$), так и ухудшением ряда показателей в случае перехода на второй индивидуальный профиль (табл. 2–4). Это свидетельствует о том, что архитектура данных моделей не подходит для классификации потенциалов SSVEP, что согласуется с результатами предыдущих исследований [13, 28] и требует пересмотра архитектурных решений.

Анализ вычислительных затрат моделей (табл. 5) показал, что ATCNet, несмотря на значительное число параметров (114 тыс.), обеспечивает скорость тестирования 0,31 секунды, что приемлемо для систем реального времени. EEG-TCNet, имея в 28 раз меньшее число параметров, демонстрирует сопоставимые показатели метрик при тестировании на профиле № 2 (табл. 2–4), что делает ее перспективной для внедрения в ресурсоемкие среды. Использование модели ATCNet в то же время целесообразно в условиях достаточных вычислительных ресурсов для достижения максимальной надежности.

Таким образом, результаты настоящего исследования подтверждают, что персонализированный выбор частот фотостимуляции является важным фактором для повышения точности и надежности классификации потенциалов SSVEP, однако успех подхода напрямую зависит и от архитектуры используемой модели. Было показано, что переход к использованию частот с наиболее выраженными реакциями оказывает положительное влияние на точность классификации и уровень согласия моделей с подходящей архитектурой, что подтверждается как вычислением метрик, так и анализом главной диагонали матриц путаницы. Модели ATCNet и EEG-TCNet продемонстрировали наилучшие результаты, что на настоящий момент делает их наиболее перспективными (из числа моделей, рассмотренных в настоящей работе) для практического применения в системах ИМК, основанных на SSVEP парадигме. В то же время низкая эффективность ряда моделей указывает на необходимость дальнейшего совершенствования их архитектуры для возможности работы в данной области. Полученные сведения будут полезны как при проектировании ИМК на этапе выбора модели МО, так и при разработке и тестировании новых архитектур.

СПИСОК ЛИТЕРАТУРЫ

1. Vidal J.J. Toward direct brain-computer communication // Annual Review of Biophysics and Bioengineering. – 1973. – Vol. 2. – P. 157–180. – DOI: 10.1146/annurev.bb.02.060173.001105. – PMID: 4583653.

2. Kozin A.V., Schetinin Y.I. The use of empirical mode decomposition for physiological artifacts suppression from electroencephalogram signals // 2021 XV International Scientific-Technical Conference on Actual Problems of Electronic Instrument Engineering (APEIE), Novosibirsk, Russian Federation, 2021. – IEEE, 2021. – P. 80–85. – DOI: 10.1109/APEIE52976.2021.9647545.
3. Левицкая О.С., Лебедев М.А. Интерфейс мозг–компьютер: будущее в настоящем // Вестник Российского государственного медицинского университета. – 2016. – № 2. – URL: <https://cyberleninka.ru/article/n/interfeys-mozg-kompyuter-buduschee-v-nastoyaschem> (дата обращения: 08.09.2025).
4. Мокиенко О.А., Черникова Л.А., Фролов А.А. Интерфейс мозг – компьютер как новая технология нейрореабилитации // Анналы клинической и экспериментальной неврологии. – 2011. – Т. 5, № 3. – С. 46–52.
5. Neuronal ensemble control of prosthetic devices by a human with tetraplegia / L.R. Hochberg, M.D. Serruya, G.M. Friehs, J.A. Mukand, M. Saleh, A.H. Caplan, A. Branner, D. Chen, R.D. Penn, J.P. Donoghue // *Nature*. – 2006. – Vol. 442 (7099). – P. 164–171. – DOI: 10.1038/nature04970.
6. Kennedy P.R., Bakay R.A.E. Restoration of neural output from a paralyzed patient by a direct brain connection // *NeuroReport*. – 1998. – Vol. 9 (8). – P. 1707–1711.
7. A review of P300, SSVEP, and hybrid P300/SSVEP brain-computer interface systems / S. Amiri, A. Rabbi, L. Azinfar, R. Fazel-Rezai // *Brain-computer interface systems: Recent progress and future prospects*. – InTech, 2013. – DOI: 10.5772/56135.
8. A multi-branch convolutional neural network with squeeze-and-excitation attention blocks for EEG-based motor imagery signals classification / G.A. Altuwaijri, G. Muhammad, H. Altaheri, M. Al-sulaiman // *Diagnostics*. – 2022. – Vol. 12 (4). – P. 995. – DOI: 10.3390/diagnostics12040995.
9. Altaheri H., Muhammad G., Alsulaiman M. Physics-informed attention temporal convolutional network for EEG-based motor imagery classification // *IEEE Transactions on Industrial Informatics*. – 2023. – Vol. 19. – P. 2249–2258. – DOI: 10.1109/TII.2022.3197419.
10. Li Z. Mamba with split-based pyramidal convolution and Kolmogorov – Arnold network-channel-spatial attention for electroencephalogram classification // *Frontiers in Sensors*. – 2025. – Vol. 6. – P. 1548729. – DOI: 10.3389/fsens.2025.1548729.
11. A hybrid steady-state visual evoked response-based brain-computer interface with MEG and EEG / X. Li, J. Chen, N. Shi, C. Yang, P. Gao, X. Chen, Y. Wang, S. Gao, X. Gao // *Expert Systems with Applications*. – 2023. – Vol. 223. – P. 119736. – DOI: 10.1016/j.eswa.2023.119736.
12. Ng K.B., Bradley A.P., Cunningham R. Stimulus specificity of a steady-state visual-evoked potential-based brain–computer interface // *Journal of Neural Engineering*. – 2012. – Vol. 9 (3). – P. 036008. – DOI: 10.1088/1741-2560/9/3/036008.
13. The largest EEG-based BCI reproducibility study for open science: the MOABB benchmark / S. Chevallier, I. Carrara, B. Aristimunya, P. Guetschel, S. Sedlar, B. Lopes, S. Velut, S. Khazem, T. Moreau. – arXiv preprint arXiv:2404.15319. – 2024.
14. A comparison study of canonical correlation analysis based methods for detecting steady-state visual evoked potentials / M. Nakanishi, Y. Wang, Y.T. Wang, T.P. Jung // *PLoS ONE*. – 2015. – Vol. 10 (10). – P. 1–18. – DOI: 10.1371/journal.pone.0140703.
15. GDNet-EEG: An attention-aware deep neural network based on group depth-wise convolution for SSVEP stimulation frequency recognition / Z. Wan, W. Cheng, M. Li, R. Zhu, W. Duan // *Frontiers in Neuroscience*. – 2023. – Vol. 17. – P. 1160040. – DOI: 10.3389/fnins.2023.1160040.
16. EEGNet: A compact convolutional network for EEG-based brain-computer interfaces / V. Lawhern, A. Solon, N. Waytowich, S. Gordon, C. Hung, B. Lance // *Journal of Neural Engineering*. – 2016. – Vol. 15. – DOI: 10.1088/1741-2552/aace8c.
17. A benchmark dataset for SSVEP-based brain-computer interfaces / Y. Wang, X. Chen, X. Gao, S. Gao // *IEEE Transactions on Neural Systems and Rehabilitation Engineering*. – 2017. – Vol. 25 (10). – P. 1746–1752. – DOI: 10.1109/TNSRE.2016.2627556.
18. OS-SSVEP: one-shot SSVEP classification / Y. Deng, Z. Ji, Y. Wang, S.K. Zhou // *Neural Networks*. – 2024. – Vol. 180. – P. 106734. – DOI: 10.1016/j.neunet.2024.106734.
19. Enhancing the performance of SSVEP-based BCIs by combining task-related component analysis and deep neural network / Q. Wei, C. Li, Y. Wang, X. Gao // *Scientific Reports*. – 2025. – Vol. 15 (1). – P. 365. – DOI: 10.1038/s41598-024-84534-6.
20. SSVEP enhancement in mixed reality environment for brain-computer interfaces / J. Wu, F. He, X. Xiao, R. Gao, L. Meng, X. Liu, M. Xu, D. Ming // *IEEE Transactions on Neural Systems and Rehabilitation Engineering*. – 2025. – Vol. 33. – P. 420–430. – DOI: 10.1109/TNSRE.2025.3526950.
21. Automating stimulation frequency selection for SSVEP-based brain-computer interfaces / A. Kozin, A. Gerasimov, M. Bakaev, A. Pashkov, O. Razumnikova // *Algorithms*. – 2023. – Vol. 16 (11). – P. 502. – DOI: 10.3390/a16110502.

22. BCI illiteracy: It's us, not them. Optimizing BCIs for individual brains / S. Becker, K. Dhindsa, L. Mousapour, Y. Al Dabagh // 10th International Winter Conference on Brain-Computer Interface (BCI), Gangwon-do, Korea. – IEEE, 2022. – P. 1–3. – DOI: 10.1109/BCI53720.2022.9735007.
23. SSVEP detection assessment by combining visual stimuli paradigms and no-training detection methods / J.D. Chailloux Peguero, L.G. Hernández-Rojas, O. Mendoza-Montoya, R. Caraza, J.M. Antelis // *Frontiers in Neuroscience*. – 2023. – Vol. 17. – P. 1142892. – DOI: 10.3389/fnins.2023.1142892.
24. On the quantification of SSVEP frequency responses in human EEG in realistic BCI conditions / R. Kuś, A. Duszyk, P. Milanowski, M. Łabecki, M. Bierzyńska, Z. Radzikowska, M. Michalska, J. Żygierewicz, P. Suffczyński, P.J. Durka // *PLoS ONE*. – 2013. – Vol. 8. – P. 1–9. – DOI: 10.1371/journal.pone.0077536.
25. Wang Y., Wang P., Yu Y. Decoding English alphabet letters using EEG phase information // *Frontiers in Neuroscience*. – 2018. – Vol. 12 – P. 62. – DOI: 10.3389/fnins.2018.00062.
26. Deep learning with convolutional neural networks for EEG decoding and visualization / R.T. Schirrmeister, J.T. Springenberg, L.D.J. Fiederer, M. Glasstetter, K. Eggenberger, M. Tangermann, F. Hutter, W. Burgard, T. Ball // *Human Brain Mapping*. – 2017. – Vol. 38. – P. 5391–5420. – DOI: 10.1002/hbm.23730.
27. Improving the performance of SSVEP-BCI contaminated by physiological noise via adversarial training / D. Wang, A. Liu, B. Xue, L. Wu, X. Chen // *Medicine in Novel Technology and Devices*. – 2023. – Vol. 18. – P. 100213. – DOI: 10.1016/j.medntd.2023.100213.
28. Employment of domain adaptation techniques in SSVEP-based brain-computer interfaces / A. Apicella, P. Arpaia, E.D. Benedetto, N. Donato, L. Duraccio, S. Giugliano, R. Prevete // *IEEE Access*. – 2023. – Vol. 11. – P. 36147–36157. – DOI: 10.1109/ACCESS.2023.3266306.
29. Toward reliable signals decoding for electroencephalogram: A benchmark study to EEGNeX / X. Chen, X. Teng, H. Chen, Y. Pan, P. Geyer. – arXiv preprint arXiv:2207.12369. – 2022.
30. EEG-TCNet: An accurate temporal convolutional network for embedded motor-imagery brain-machine interfaces / T.M. Ingolfsson, M. Hersche, X. Wang, N. Kobayashi, L. Cavigelli, L. Benini // *IEEE International Conference on Systems, Man, and Cybernetics (SMC)*. – IEEE, 2020. – P. 2958–2965. – DOI: 10.1109/SMC42975.2020.9283028.
31. A multi-branch convolutional neural network with squeeze-and-excitation attention blocks for EEG-based motor imagery signals classification / A.A. Ghadir, M. Ghulam, A. Hamdi, A. Mansour // *Diagnostics*. – 2022. – Vol. 12 (4). – DOI: 10.3390/diagnostics12040995.
32. Pan Y.T., Chou J.L., Wei C.S. MAtt: A manifold attention network for EEG decoding // *Advances in Neural Information Processing Systems 35: 36th Conference on Neural Information Processing Systems (NeurIPS 2022)*. – NIPS, 2022. – Vol. 35.
33. Electroencephalography-based motor imagery classification using temporal convolutional network fusion / Y.K. Musallam, N.I. AlFassam, G. Muhammad, S.U. Amin, M. Alsulaiman, W. Abdul, H. Altaheri, M.A. Bencherif, M. Algabri // *Biomedical Signal Processing and Control*. – 2021. – Vol. 69. – DOI: 10.1016/j.bspc.2021.102826.

Козин Алексей Викторович, аспирант Новосибирского государственного технического университета, ассистент кафедры систем сбора и обработки данных, инженер лаборатории «Биотехнические системы». Специальность 05.13.11. «Математическое и программное обеспечение вычислительных машин, комплексов и компьютерных сетей». Область научных интересов: информационно-измерительные системы, цифровая обработка сигналов, интерфейсы мозг-компьютер. E-mail: JasderoR440@gmail.com

Герасимов Антон Константинович, аспирант Новосибирского государственного технического университета, ассистент и ученый секретарь кафедры систем сбора и обработки данных, инженер лаборатории «Биотехнические системы». Специальность 2.2.12. «Приборы, системы и изделия медицинского назначения». Область научных интересов: цифровая обработка сигналов и изображений, биомедицинские исследования, интерфейсы мозг-компьютер. E-mail: geraplusplus@gmail.com

Бакаев Максим Александрович, кандидат технических наук, доцент, заведующий кафедрой систем сбора и обработки данных Новосибирского государственного технического университета. Область научных интересов: взаимодействие в системах «человек – искусственный интеллект», пользовательские интерфейсы, информационные системы, когнитивная психология, машинное обучение, качество данных, анализ естественного языка. E-mail: bakaev@corp.nstu.ru

Kozin Alexey V., PhD student in the Novosibirsk State Technical University, assistant lecturer at the Department of Data Acquisition and Processing Systems, engineer at the “Biotech-

nical Systems” laboratory. Specialization 05.13.11 “Mathematical and Software Support for Computers, Complexes and Computer Networks”. His research interests include information-measuring systems, digital signal processing, and brain-computer interfaces. E-mail: JasderoR440@gmail.com

Gerasimov Anton K., PhD student in the Novosibirsk State Technical University, assistant lecturer and scientific secretary at the Department of Data Acquisition and Processing Systems, engineer at the “Biotechnical Systems” laboratory. Specialization 2.2.12 “Devices, Systems and Products for Medical Purposes”. His research interests include digital signal and image processing, biomedical research, and brain-computer interfaces. E-mail: geraplusplus@gmail.com

Bakaev Maxim A., PhD, Associate Professor, Department Head of Data Collection and Processing Systems. His research interests cover Human-AI Interaction, User Interfaces, Information Systems, Cognitive Psychology, Machine Learning, Data Quality, and Natural Language Processing. E-mail: bakaev@corp.nstu.ru

DOI: 10.17212/2782-2001-2025-3-45-68

An individualized approach to selecting photostimulation frequency in BCI systems based on the SSVEP paradigm and machine learning models*

A.V. KOZHIN^a, A.K. GERASIMOV^b, M.A. BAKAEV^c

Novosibirsk State Technical University, 20 K. Marx Prospekt, Novosibirsk, 630073, Russian Federation

^a JasderoR440@gmail.com ^b geraplusplus@gmail.com ^c bakaev@corp.nstu.ru

Abstract

Brain-computer interfaces (BCIs) provide users with alternative communication channels for interacting with peripheral devices of various purposes and constitute a significant area of research in medicine and neurorehabilitation. Multiple paradigms exist for designing such systems, each with distinct characteristics. One such paradigm is based on Steady-State Visually Evoked Potentials (SSVEP). Its key advantage lies in its minimal user training requirements for BCI operation. However, it is also marked by individual variability in users' responses to photostimulation, which introduces specific challenges. Current research suggests that addressing this variability could be a significant step toward enhancing the accuracy and efficiency of SSVEP-based BCIs.

With the progress in machine learning (ML), various methods are increasingly employed to analyze biomedical signals. Novel models and architectures are being proposed for domain-specific applications. This trend extends to BCIs, where ML is applied to classify input data represented as electroencephalogram (EEG) signal epochs. This study aims to investigate the impact of incorporating individual user responses on the classification performance of ML models used in BCI design. Several models previously applied to MI, SSVEP, P300, and other paradigms were tested such as ATCNet, DeepConvNet, EEGNet, EEGNeX, EEG-TCNet, MBEEG_SENet, ShallowConvNet and TCNet_Fusion. The open-access datasets “12JFPM” and “TsinghuaBCI_Benchmark” were utilized, providing experimental data from 45 subjects' in total. Using the EEG signal-to-noise ratio (SNR) as an indicator of response intensity, a frequency-specific compatibility coefficient was determined for each photostimulation frequency. Individual subject profiles were then created, each containing 4 frequencies with the highest and lowest compatibility coefficients, enabling the evaluation of model performance under two contrasting conditions.

The results demonstrate that accounting for individual responses positively impact the performance metrics of leading ML models, such as classification accuracy and Cohen's kappa coefficient, particularly for ATCNet and EEG-TCNet. The paired Student's t-test confirmed the statistical significance of these improvements for ATCNet and EEG-TCNet ($p < 0,01$) and for MBEEG_SENet and TCNet_Fusion ($p < 0,05$). The averaged values along the main diagonal of the confusion matrices for these models exhibit a consistent positive trend.

Keywords: brain-computer interfaces, steady-state visually evoked potentials, biomedical signals, electroencephalogram, machine learning, individual user response, signal-to-noise ratio, frequency compatibility coefficient, classification accuracy, Cohen's kappa, confusion matrix

* Received 04 March 2025.

REFERENCES

1. Vidal J.J. Toward direct brain-computer communication. *Annual Review of Biophysics and Bioengineering*, 1973, vol. 2, pp. 157–180. DOI: 10.1146/annurev.bb.02.060173.001105. PMID: 4583653.
2. Kozin A.V., Schetinin Y.I. The use of empirical mode decomposition for physiological artifacts suppression from electroencephalogram signals. 2021 XV International Scientific-Technical Conference on Actual Problems of Electronic Instrument Engineering (APEIE), Novosibirsk, Russian Federation, 2021, pp. 80–85. DOI: 10.1109/APEIE52976.2021.9647545.
3. Levitskaya O.S., Lebedev M.A. Interfeis mozg–komp'yuter: budushchee v nastoyaschem [Brain-computer interface: the future in the present]. *Vestnik Rossiiskogo gosudarstvennogo meditsinskogo universiteta = Bulletin of Russian state medical university*, 2016, no. 2. Available at: <https://cyberleninka.ru/article/n/interfeys-mozg-kompyuter-budushchee-v-nastoyaschem> (accessed 08.09.2025).
4. Mokienko O.A., Chernikova L.A., Frolov A.A. Interfeis mozg-komp'yuter kak novaya tekhnologiya neiroreabilitatsii [Brain-computer interface as a novel tool of neurorehabilitation]. *Annaly klinicheskoi i eksperimental'noi nevrologii = Annals of Clinical and Experimental Neurology*, 2011, vol. 5, no. 3, pp. 46–52.
5. Hochberg L.R., Serruya M.D., Friehs G.M., Mukand J.A., Saleh M., Caplan A.H., Branner A., Chen D., Penn R.D., Donoghue J.P. Neuronal ensemble control of prosthetic devices by a human with tetraplegia. *Nature*, 2006, vol. 442 (7099), pp. 164–171. DOI: 10.1038/nature04970.
6. Kennedy P.R., Bakay R.A.E. Restoration of neural output from a paralyzed patient by a direct brain connection. *NeuroReport*, 1998, vol. 9 (8), pp. 1707–1711.
7. Amiri S., Rabbi A., Azinfar L., Fazel-Rezai R. A review of P300, SSVEP, and hybrid P300/SSVEP. *Brain-computer interface systems: Recent progress and future prospects*. InTech, 2013. DOI: 10.5772/56135.
8. Altuwaijri G.A., Muhammad G., Altaheri H., Alsulaiman M. A multi-branch convolutional neural network with squeeze-and-excitation attention blocks for EEG-based motor imagery signals classification. *Diagnostics*, 2022, vol. 12 (4), p. 995. DOI: 10.3390/diagnostics12040995.
9. Altaheri H., Muhammad G., Alsulaiman M. Physics-informed attention temporal convolutional network for EEG-based motor imagery classification. *IEEE Transactions on Industrial Informatics*, 2023, vol. 19, pp. 2249–2258. DOI: 10.1109/TH.2022.3197419.
10. Li Z. Mamba with split-based pyramidal convolution and Kolmogorov – Arnold network-channel-spatial attention for electroencephalogram classification. *Frontiers in Sensors*, 2025, vol. 6, p. 1548729. DOI: 10.3389/fsens.2025.1548729.
11. Li X., Chen J., Shi N., Yang C., Gao P., Chen X., Wang Y., Gao S., Gao X. A hybrid steady-state visual evoked response-based brain-computer interface with MEG and EEG. *Expert Systems with Applications*, 2023, vol. 223, p. 119736. DOI: 10.1016/j.eswa.2023.119736.
12. Ng K.B., Bradley A.P., Cunnington R. Stimulus specificity of a steady-state visual-evoked potential-based brain–computer interface. *Journal of Neural Engineering*, 2012, vol. 9 (3), p. 036008. DOI: 10.1088/1741-2560/9/3/036008.
13. Chevallier S., Carrara I., Aristimunha B., Guetschel P., Sedlar S., Lopes B., Velut S., Khazem S., Moreau T. *The largest EEG-based BCI reproducibility study for open science: the MOABB benchmark*. arXiv preprint arXiv:2404.15319. 2024.
14. Nakanishi M., Wang Y., Wang Y.T., Jung T.P. A comparison study of canonical correlation analysis based methods for detecting steady-state visual evoked potentials. *PLoS ONE*, 2015, vol. 10 (10), pp. 1–18. DOI: 10.1371/journal.pone.0140703.
15. Wan Z., Cheng W., Li M., Zhu R., Duan W. GDNet-EEG: An attention-aware deep neural network based on group depth-wise convolution for SSVEP stimulation frequency recognition. *Frontiers in Neuroscience*, 2023, vol. 17, p. 1160040. DOI: 10.3389/fnins.2023.1160040.
16. Lawhern V., Solon A., Waytowich N., Gordon S., Hung C., Lance B. EEGNet: A compact convolutional network for EEG-based brain-computer interfaces. *Journal of Neural Engineering*, 2016, vol. 15. DOI: 10.1088/1741-2552/aace8c.
17. Wang Y., Chen X., Gao X., Gao S. A benchmark dataset for SSVEP-based brain-computer interfaces. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2017, vol. 25 (10), pp. 1746–1752. DOI: 10.1109/TNSRE.2016.2627556.
18. Deng Y., Ji Z., Wang Y., Zhou S.K. OS-SSVEP: one-shot SSVEP classification. *Neural Networks*, 2024, vol. 180, p. 106734. DOI: 10.1016/j.neunet.2024.106734.
19. Wei Q., Li C., Wang Y., Gao X. Enhancing the performance of SSVEP-based BCIs by combining task-related component analysis and deep neural network. *Scientific Reports*, 2025, vol. 15 (1), p. 365. DOI: 10.1038/s41598-024-84534-6.

20. Wu J., He F., Xiao X., Gao R., Meng L., Liu X., Xu M., Ming D. SSVEP enhancement in mixed reality environment for brain-computer interfaces. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2025, vol. 33, pp. 420–430. DOI: 10.1109/TNSRE.2025.3526950.
21. Kozin A., Gerasimov A., Bakaev M., Pashkov A., Razumnikova O. Automating stimulation frequency selection for SSVEP-based brain-computer interfaces. *Algorithms*, 2023, vol. 16 (11), p. 502. DOI: 10.3390/a16110502.
22. Becker S., Dhindsa K., Mousapour L., Al Dabagh Y. BCI illiteracy: It's us, not them. Optimizing BCIs for individual brains. *10th International Winter Conference on Brain-Computer Interface (BCI)*, Gangwon-do, Korea. IEEE, 2022, pp. 1–3. DOI: 10.1109/BCI53720.2022.9735007.
23. Chailloux Peguero J.D., Hernández-Rojas L.G., Mendoza-Montoya O., Caraza R., Antelis J.M. SSVEP detection assessment by combining visual stimuli paradigms and no-training detection methods. *Frontiers in Neuroscience*, 2023, vol. 17, p. 1142892. DOI: 10.3389/fnins.2023.1142892.
24. Kuś R., Duszyk A., Milanowski P., Łabecki M., Bierzyńska M., Radzikowska Z., Michalska M., Żygierewicz J., Suffczyński P., Durka P.J. On the quantification of SSVEP frequency responses in human EEG in realistic BCI conditions. *PLoS ONE*, 2013, vol. 8, pp. 1–9. DOI: 10.1371/journal.pone.0077536.
25. Wang Y., Wang P., Yu Y. Decoding English alphabet letters using EEG phase information. *Frontiers in Neuroscience*, 2018, vol. 12, p. 62. DOI: 10.3389/fnins.2018.00062.
26. Schirrmester R.T., Springenberg J.T., Fiederer L.D.J., Glasstetter M., Eggenberger K., Tangermann M., Hutter F., Burgard W., Ball T. Deep learning with convolutional neural networks for EEG decoding and visualization. *Human Brain Mapping*, 2017, vol. 38, pp. 5391–5420. DOI: 10.1002/hbm.23730.
27. Wang D., Liu A., Xue B., Wu L., Chen X. Improving the performance of SSVEP-BCI contaminated by physiological noise via adversarial training. *Medicine in Novel Technology and Devices*, 2023, vol. 18, p. 100213. DOI: 10.1016/j.medntd.2023.100213.
28. Apicella A., Arpaia P., Benedetto E.D., Donato N., Duraccio L., Giugliano S., Prevete R. Employment of domain adaptation techniques in SSVEP-based brain-computer interfaces. *IEEE Access*, 2023, vol. 11, pp. 36147–36157. DOI: 10.1109/ACCESS.2023.3266306.
29. Chen X., Teng X., Chen H., Pan Y., Geyer P. *Toward reliable signals decoding for electroencephalogram: A benchmark study to EEGNeX*. arXiv preprint arXiv:2207.12369. 2022.
30. Ingolfsson T.M., Hersche M., Wang X., Kobayashi N., Cavigelli L., Benini L. EEG-TCNet: An accurate temporal convolutional network for embedded motor-imagery brain-machine interfaces. *IEEE International Conference on Systems, Man, and Cybernetics (SMC)*, 2020, pp. 2958–2965. DOI: 10.1109/SMC42975.2020.9283028.
31. Ghadir A.A., Ghulam M., Hamdi A., Mansour A. A multi-branch convolutional neural network with squeeze-and-excitation attention blocks for EEG-based motor imagery signals classification. *Diagnostics*, 2022, vol. 12 (4). DOI: 10.3390/diagnostics12040995.
32. Pan Y.T., Chou J.L., Wei C.S. MAtt: A manifold attention network for EEG decoding. *Advances in Neural Information Processing Systems 35: 36th Conference on Neural Information Processing Systems (NeurIPS 2022)*. NIPS, 2022, vol. 35.
33. Musallam Y.K., AlFassam N.I., Muhammad G., Amin S.U., Alsulaiman M., Abdul W., Altaheri H., Bencherif M.A., Algabri M. Electroencephalography-based motor imagery classification using temporal convolutional network fusion. *Biomedical Signal Processing and Control*, 2021, vol. 69. DOI: 10.1016/j.bspc.2021.102826.

Для цитирования:

Козин А.В., Герасимов А.К., Бакаев М.А. Индивидуальный подход к выбору частоты фотостимуляции в системах ИМК на основе SSVEP парадигмы и моделей машинного обучения // Системы анализа и обработки данных. – 2025. – № 3 (99). – С. 45–68. – DOI: 10.17212/2782-2001-2025-3-45-68.

For citation:

Kozin A.V., Gerasimov A.K., Bakaev M.A. Individual'nyi podkhod k vyboru chastoty fotostimulyatsii v sistemakh IMK na osnove SSVEP-paradigmy i modelei mashinnogo obucheniya [An individualized approach to selecting photostimulation frequency in BCI systems based on the SSVEP paradigm and machine learning models]. *Sistemy analiza i obrabotki dannykh = Analysis and Data Processing Systems*, 2025, no. 3 (99), pp. 45–68. DOI: 10.17212/2782-2001-2025-3-45-68.

ISSN 2782-2001, <http://journals.nstu.ru/vestnik>
 Analysis and data processing systems
 Vol. 99, No 3, 2025, pp. 45–68