

# Типологическая классификация сенсомоторных ЭЭГ-спектрограмм с использованием адаптированных сверточных сетей<sup>1</sup>

Д. А. Вольф, Я. А. Туровский, С. Б. Галина, Р. Р. Галин

Институт проблем управления им В.А. Трапезникова Российской академии наук, Москва, Россия.  
Поступила в редколлегию 28.08.2025 г. Принята 10.10.2025 г.

**Аннотация**—Статья посвящена задаче классификации электроэнцефалографических сигналов на основе их частотно-временных характеристик с применением адаптированных сверточных нейронных сетей. В исследовании показано, что эффективность автоматического анализа существенно возрастает при целенаправленной модификации архитектур под свойства биомедицинских данных. Такой подход отражает принцип “сигнал определяет сеть”: выбор и доработка модели должны учитывать характер спектральных признаков и особенности динамики мозговых ритмов. Для реализации этой идеи исходные сигналы преобразовывались в частотно-временные карты, которые рассматривались как изображения и использовались для обучения нейронных сетей. При этом классические архитектуры были адаптированы: одни упрощались для повышения вычислительной эффективности, другие – оптимизировались для работы с одноканальными данными, третьи – усиливались за счет остаточных связей и методов регуляризации. Проведенные эксперименты показали, что все модифицированные варианты сохраняют устойчивость обучения и способность корректно выделять информативные паттерны. При этом каждая из адаптаций имеет свои преимущества: LiteResNet2D обеспечивает наибольшую точность, LiteMobileNet2D лучше всего подходит для ресурсоограниченных устройств, SimpleAlexNet2D удобна для прототипирования и быстрой проверки гипотез. Исследование демонстрирует, что адаптация сверточных архитектур под характеристики электроэнцефалографических сигналов является ключевым условием для построения надежных и переносимых систем классификации. Этот подход открывает путь к созданию специализированных инструментов анализа, которые можно масштабировать и использовать в различных когнитивных и клинических приложениях.

**Ключевые слова:** электроэнцефалография, биометрическая, глубокое обучение, сверточные нейронные сети, сенсомоторные ритмы, нейроинтерфейс.

DOI: 10.53921/18195822\_2025\_25\_3\_284

## 1. ВВЕДЕНИЕ

Развитие нейрокомпьютерных интерфейсов (BCI) на основе электроэнцефалографии (ЭЭГ) демонстрирует впечатляющий прогресс. Так, в ряде исследований показана возможность управления сложными внешними устройствами при активации сенсомоторных ритмов [1], совместного управления одним объектом несколькими операторами [2–4], а также построения гибридных интерфейсов на основе устойчивого зрительного вызванного потенциала и миганий [5]. Предложенные в MIT гибридные архитектуры типа MuWaveNet (CNN+LSTM) увеличили точность распознавания моторных образов до 85 % [6].

<sup>1</sup> Исследование выполнено за счет гранта Российского научного фонда № 23-19-00664, <https://rscf.ru/project/23-19-00664/>.

Однако ключевой проблемой остается невозможность прямого переноса “универсальных” моделей между пользователями. При смене субъекта точность классификации падает на 20–30 % [7, 8], что обусловлено высокой межиндивидуальной и внутрисубъектной вариативностью корковой активности. Унифицированные алгоритмы глубокого обучения усредняют популяционные феномены, нивелируя устойчивые типоспецифические признаки, что ограничивает их эффективность [9, 10].

В связи с этим возникает необходимость смещения исследовательского акцента с “универсальных” моделей на типологизацию ЭЭГ, то есть выявление устойчивых паттернов, характерных для определенных групп пользователей, и подбор архитектур обработки, способных к самоадаптации. Принцип “свойство сигнала – тип сети” предполагает, что, например, для сигналов с выраженной динамикой в начале окна более устойчивы ResNet-образные архитектуры, компенсирующие переходные артефакты, тогда как для длительных сегментов с ослабленным ритмическим паттерном предпочтительнее рекуррентные или гибридные CNN-LSTM сети. Экспериментальные данные подтверждают, что распределение ошибок классификации существенно различается по временным отрезкам сигнала и требует архитектур, способных к адаптации к локальной временной структуре.

В 2023 году была продемонстрирована возможность извлечения индивидуально-типологических особенностей ЭЭГ на основе динамики частотной активности с использованием AlexNet и MobileNetV2 [11]. При этом было показано, что специализированные сети точнее фиксируют изменения спектральных характеристик, чем универсальные классификаторы. Дополнительные исследования подтвердили, что меж- и внутрисубъектная вариабельность остается фундаментальной проблемой [12, 13], и ее преодоление возможно только через разработку адаптивных моделей.

Таким образом, перспективным направлением развития ВСГ является системный подбор архитектур искусственных нейронных сетей под свойства ЭЭГ-сигналов, обеспечивающий баланс между устойчивостью к артефактам и чувствительностью к типоспецифическим признакам. Такой подход позволяет рассматривать адаптацию сетей не как дополнительный этап, а как неотъемлемый элемент типологической классификации ЭЭГ, обеспечивающий надежность и переносимость интерфейсов в реальных когортных условиях [14, 15].

Авторы описали подготовку экспериментальных данных на основе сигналов ЭЭГ, полученных в ходе экспериментов по формированию стационарных зрительно вызванных потенциалов в группе испытуемых, с последующим созданием прикладной базы данных.

Для проверки гипотезы о том, что индивидуально-типологические особенности ЭЭГ задают различные траектории обучения нейросетей и, как следствие, обуславливают неодинаковую эффективность даже при использовании идентичных архитектур в контуре ИМК, была проведена оценка репрезентативности собранных данных. Частотно-временные характеристики сигналов использовались как обучающие выборки для двух моделей глубокого обучения, которые выделяли типовые паттерны ЭЭГ с точностью около 70 %.

Адекватность и устойчивость классификаторов оценивались методами понижения размерности (PCA и t-SNE), что позволило выявить группировки по типологическим признакам и сопоставить их с особенностями “траекторий” обучения. Полученные результаты подтвердили, что вариативность ЭЭГ-профилей действительно влияет на результативность глубоких моделей, даже при условии применения унифицированных архитектур.

Исследование рассматривает возможности адаптации систем обработки ЭЭГ к задачам типологизации через применение глубокого обучения к сенсомоторным ЭЭГ-спектрограммам, зарегистрированным в строго контролируемых условиях. Сенсомоторные ритмы (мю- и бета-диапазоны), генерируемые при выполнении когнитивных и моторных задач, содержат устойчи-

вые для каждого индивидуума паттерны, которые могут использоваться как типологические маркеры.

Практическая значимость работы заключается в:

- разработке энергоэффективных алгоритмов для портативных нейроинтерфейсов, способных выделять типоспецифические признаки ЭЭГ в реальном времени;
- демонстрации воспроизводимости результатов на стандартизированной выборке, что является критическим условием для дальнейших когортных и клинических исследований;
- верификации подхода на четырехэлектродной системе, что облегчает интеграцию в коммерческие нейрогаджеты без необходимости применения 64–128-канальных комплексов.

Экспериментально показано, что предложенные архитектуры LiteResNet2D и LiteMobileNet2D достигают  $F1\text{-score} = 0.91$  на стандартизированном наборе данных. Это подтверждает их высокую эффективность для типологизации ЭЭГ и открывает перспективы создания новых систем анализа индивидуально-типологических особенностей мозга.

Таким образом, актуальность исследования определяется следующими аспектами:

1. Разработка методов типологизации биомедицинских сигналов на основе ЭЭГ.
2. Расширение возможностей применения нейрокомпьютерных интерфейсов за счет адаптации архитектур под индивидуальные паттерны активности.
3. Вклад в фундаментальное понимание вариативности мозговой активности и ее влияния на эффективность алгоритмов глубокого обучения.

## 2. ФОРМИРОВАНИЕ И СТАНДАРТИЗАЦИЯ ЭКСПЕРИМЕНТАЛЬНОЙ БАЗЫ ЭЭГ


В эксперименте приняли участие 30 здоровых добровольцев (18 мужчин и 12 женщин) в возрасте от 17 до 23 лет. На момент проведения исследования у испытуемых не было выявлено неврологических или психиатрических нарушений. В качестве критериев исключения рассматривались: прием психотропных препаратов менее чем за 72 часа до начала эксперимента, а также некорректируемые нарушения зрения. Для обеспечения конфиденциальности каждому участнику был присвоен уникальный идентификационный код (№ 1–30), что позволило проследить индивидуальные особенности зарегистрированных ЭЭГ-паттернов без раскрытия персональных данных.<sup>1</sup>

Регистрация биоэлектрической активности проводилась с использованием активных электродов F3, F7, F4 и F8, расположенных в лобно-фронтальной области, которая функционально связана с сенсомоторными процессами.

Частота дискретизации составляла 5000 Гц, что обеспечивало высокое временное разрешение и позволяло фиксировать быстрые нейронные события. Для подавления сетевых артефактов применялся онлайн-режекторный фильтр на 50 Гц. Фильтры высоких (HPF) и низких (LPF) частот на этапе записи не использовались, что позволило сохранить исходную динамику сигнала.

В последующей обработке данные проходили полосовую фильтрацию в диапазоне 1–300 Гц, что устраняло низкочастотный дрейф и высокочастотные мышечные помехи. Спектральный анализ показал наличие выраженного пика в диапазоне около 11 Гц, что соответствует

<sup>1</sup> Все процедуры, выполненные в исследованиях с участием людей, соответствуют этическим стандартам национального комитета по исследовательской этике и Хельсинкской декларации 1964 г. и ее последующим изменениям или сопоставимым нормам этики. От каждого из включенных в исследование участников было получено информированное добровольное согласие (протокол 42-02 от 08.06.2020 этического комитета по биомедицинским исследованиям). Перед проведением эксперимента с испытуемых осуществляется сбор анамнеза на наличие противопоказаний.



**Рис. 1.** Пример “частотного” изображения для распознавания.

типичным характеристикам мю-ритма у взрослых испытуемых. Статистическая обработка частотного спектра подтвердила наличие значимой активности в указанном диапазоне.

Выявленные свойства мю-ритма соответствуют литературным данным, согласно которым его частота стабилизируется на уровне около 10 Гц. Анализ временной динамики выявил типичную для мю-ритма организацию колебательной активности, включающую периоды десинхронизации и последующей ресинхронизации. Эти результаты демонстрируют корректность методики регистрации и обработки ЭЭГ-сигнала и подтверждают наличие типичных ритмических характеристик у исследуемого субъекта, что создает основу для последующего анализа функциональных особенностей активности мозга.

В процессе предварительной обработки данных осуществлялась экстракция репрезентативных и разделимых признаков для последующего применения алгоритмов глубокого обучения и классификации. В качестве информативных характеристик была выбрана динамика изменения частотных составляющих сигнала во временной области. Для извлечения частотных параметров использовалось оконное преобразование Фурье.

По результатам обработки были сформированы наборы спектрограмм для каждого испытуемого. Каждая спектрограмма сегментировалась на фрагменты размером  $32 \times 32$  пикселя с перекрытием окон на 25 %, что обеспечивало аугментацию данных. Итоговый датасет включал 3720 образцов.

Сформированные обучающие выборки представляли собой персонализированные частотно-временные карты, содержащие сигналы от каждого участника. Такой формат позволял использовать данные в качестве входных признаков для глубоких моделей классификации [16, 17]. На Рис. 3 представлен пример электроэнцефалограммы в частотно-временной развертке для зоны F3.

На Рис. 1 приведен пример частотно-временной карты, сформированной по данным ЭЭГ. Горизонтальная ось отображает временную развертку, а вертикальная – частотные компоненты сигнала. Цветовая шкала кодирует амплитуду спектральной мощности: более теплые оттенки (желтый, светло-зеленый) соответствуют повышенной активности в данных частотных диапазонах, тогда как темные области указывают на минимальную выраженность сигнала.

Из представленного примера видно, что спектральная энергия сосредоточена преимущественно в низкочастотной области (до 10–12 Гц), где фиксируются стабильные полосы активности, характерные для сенсомоторных ритмов (в частности,  $\mu$ -ритма). Подобные изображения использовались в качестве входных признаков для алгоритмов глубокого обучения: они отражают вариативность спектральных характеристик, что используется при типологическом анализе и позволяют выделять устойчивые паттерны, значимые для задач типологической классификации.

Методологическая схема эксперимента демонстрирует целостный и строго структурированный подход. В исследование была включена группа, чей возрастной диапазон обеспечивает относительную однородность психофизиологических параметров, что снижает влияние возрастных факторов на вариативность сигналов. Критерии включения предполагали отсутствие неврологических и психиатрических нарушений, отказ от приема психотропных препаратов, а также корреktированное зрение, что минимизировало вероятность искажений при регистрации ЭЭГ. Техническая часть эксперимента была организована с учетом современных требований к точности регистрации. Несмотря на относительно ограниченный объем выборки и необходимость учета половых различий в будущих когортных исследованиях, полученные данные представляют собой качественную основу для анализа. Сформированная методология позволяет выделять устойчивые частотно-временные паттерны ЭЭГ и использовать их для построения типологических классификаций, что создает предпосылки для дальнейшей разработки и валидации алгоритмов глубокого обучения в рамках нейрокомпьютерных интерфейсов.

### 3. ПОДХОДЫ К АДАПТАЦИИ ГЛУБОКИХ МОДЕЛЕЙ ДЛЯ АНАЛИЗА ЭЭГ В СПЕКТРАЛЬНОЙ ОБЛАСТИ

Для решения задачи классификации ЭЭГ-спектрограмм были использованы три модифицированные архитектуры сверточных нейронных сетей: SimpleAlexNet, LiteMobileNet2D и LiteResNet2D. Все модели были адаптированы для работы с одноканальными входными изображениями. Их применение в анализе ЭЭГ-спектрограмм обусловлено рядом принципиальных свойств:

1. Локальная связность – нейроны ориентируются на ограниченные области входных данных, что критически важно при анализе частотно-временных паттернов;
2. Разделение весов – использование общих сверточных ядер снижает вычислительные затраты и уменьшает риск переобучения;
3. Иерархичность признаков – поэтапное извлечение как низкоуровневых (границы, текстурные элементы), так и высокоуровневых характеристик (ритмическая активность, фазовые изменения).

Для применения в задачах обработки ЭЭГ-данных каждая архитектура была модифицирована с учетом особенностей исходных данных – спектрограмм:

- SimpleAlexNet – упрощенная версия AlexNet, сохраняющая базовую сверточную структуру, но адаптированная за счет сокращения числа параметров, что делает ее пригодной для вычислительно ограниченных устройств;
- LiteMobileNet2D – облегченная модификация MobileNetV2, использующая depthwise-свертки для повышения энергоэффективности и оптимизации под портативные нейроинтерфейсы;
- LiteResNet2D – адаптированный вариант ResNet, включающий residual-блоки, которые предотвращают затухание градиентов и повышают устойчивость обучения на ограниченных по размеру датасетах.

Все три архитектуры были оптимизированы под ограниченные вычислительные ресурсы, что делает их применимыми в составе портативных нейроинтерфейсов реального времени.

Концепция автоматической классификации ЭЭГ-сигналов строилась на использовании спектрограмм, рассматриваемых в качестве одноканальных изображений. На вход сети поступала спектрограмма, после чего каскад сверточных слоев последовательно выделял локальные узоры, формируя набор карт признаков. Далее полученные признаки обобщались полносвязным слоем, который выполнял сопоставление с целевыми классами.

Для адаптации выбранных архитектур к специфике ЭЭГ-данных были внесены ключевые изменения: стандартные RGB-входы заменены на одноканальные для корректной работы со спектрограммами; глубина сетей уменьшена с целью снижения вычислительной нагрузки; добавлены слои Dropout, обеспечивающие устойчивость обучения и компенсацию шумовых артефактов.

В такой конфигурации модель получает на вход спектрограмму, а предварительно обученная сеть выполняет классификацию, соотнося запись ЭЭГ с соответствующим классом на основе ее характерных частотных признаков.

### *3.1. Адаптация архитектуры AlexNet под низкоразмерные ЭЭГ-спектрограммы*

Архитектура AlexNet, ставшая фундаментальной в эпоху возрождения глубокого обучения, заложила основы современных сверточных нейронных сетей благодаря комбинации сверточных слоев, функций активации ReLU и методов регуляризации. Однако ее первоначальная ориентация на изображения высокого разрешения ( $227 \times 227$  пикселей) и использование вычислительно нагруженных полносвязных слоев по 4096 нейронов делают ее избыточной при работе с низкоразмерными биомедицинскими данными, включая ЭЭГ-спектрограммы.

Для решения этой задачи предложена модификация SimpleAlexNet, в которой архитектура оптимизирована для работы с входами размером  $32 \times 32$  пикселя и дополнена средствами регуляризации. Все сверточные слои используют ядра  $3 \times 3$  с padding=1, заменяющие избыточные фильтры  $11 \times 11$  и  $5 \times 5$  оригинала. Постепенное наращивание числа карт признаков ( $64 \rightarrow 192 \rightarrow 384 \rightarrow 256 \rightarrow 256$ ) обеспечивает плавное усложнение представлений без риска переобучения. Операции субдискретизации (MaxPool2d,  $2 \times 2$ ) выполняются выборочно – только после 1-го, 2-го и 5-го слоев, что позволяет сохранить критически важные частотные детали.

Классификационный блок также упрощен: три полносвязных слоя  $4096 \rightarrow 4096 \rightarrow 1000$  заменены последовательностью  $1024 \rightarrow 512 \rightarrow 30$ , что сокращает число параметров примерно на 95 % и делает архитектуру сопоставимой с размерностью задачи. Для борьбы с шумом и коадаптацией нейронов реализована двойная регуляризация Dropout (50 % на входе сверточного блока и 30 % между полносвязными слоями), а также добавлена пакетная нормализация (BatchNorm1d) для стабилизации распределений активаций. Завершающий слой представляет собой линейную проекцию на 30 классов, адаптированную к функции потерь CrossEntropyLoss.

В таблице 1 представлено сравнение оригинальной архитектуры AlexNet и предложенной модификации.

**Таблица 1.** Сравнение SimpleAlexNet с оригинальным AlexNet

| Компонент         | AlexNet (оригинал)                   | SimpleAlexNet (авторский)                           |
|-------------------|--------------------------------------|-----------------------------------------------------|
| Сверточные слои   | 5 (96–256–384–384–256 фильтров)      | 3–4 (упрощенные фильтры $3 \times 3$ )              |
| Полносвязные слои | 3 (4096–4096–1000 нейронов)          | 1–2 (512–256 нейронов)                              |
| Нормализация      | Local Response Norm (LRN)            | BatchNorm1d (в Dense-слоях)                         |
| Пулинг            | 3 MaxPool ( $3 \times 3$ , stride=2) | 2–3 MaxPool ( $2 \times 2$ ,<br>выборочные позиции) |
| Активация         | ReLU (ограничение 6)                 | Обычные ReLU                                        |

Модификация AlexNet в архитектуре SimpleAlexNet продемонстрировала эффективность при работе с низкоразмерными ЭЭГ-спектрограммами. Упрощенная структура с компактными свертками и уменьшенными полносвязными слоями существенно сократила число параметров, сохранив при этом способность выделять устойчивые биометрические паттерны. Усиленная регуляризация и использование пакетной нормализации обеспечили устойчивость модели к шуму и улучшили ее обучаемость на ограниченных выборках. Таким образом, SimpleAlexNet можно рассматривать как оптимальный базовый вариант для быстрого и энергоэффективного анализа биомедицинских сигналов.

### 3.2. Адаптация архитектуры MobileNetV2 для анализа ЭЭГ-спектрограмм

Архитектура MobileNetV2, изначально разработанная для ресурсоемких сценариев (мобильные устройства, встроенные системы), основана на применении инвертированных остаточных блоков (inverted residuals) и depthwise-сверток, что позволяет достичь баланса между вычислительной эффективностью и точностью. Важные инновации включают использование функции активации ReLU6, устойчивой к квантованию, и замену полносвязных слоев глобальным пулингом. Благодаря этим особенностям MobileNetV2 стала одной из эталонных моделей для задач классификации изображений (например, Top-1 accuracy 75.3 % на ImageNet) и сегментации.

Однако при применении к одноканальным биомедицинским данным, таким как ЭЭГ-спектрограммы, стандартная конфигурация требует адаптации. Для этого была предложена модификация LiteMobileNet2D, направленная на упрощение архитектуры и повышение ее устойчивости к работе на малых датасетах.

В модифицированной версии входной stem-блок был заменен на свертку  $3 \times 3$  с шагом 2, что обеспечивает быстрое уменьшение пространственного разрешения. Вместо ReLU6 используется функция активации SiLU (Swish), которая улучшает градиентный поток на монохромных данных и позволяет сохранить низкоуровневые частотно-временные паттерны (например, сенсомоторные ритмы). Количество инвертированных остаточных блоков было сокращено с 19 до 6, при этом прогрессия каналов изменена ( $32 \rightarrow 16 \rightarrow 24 \rightarrow \dots \rightarrow 64$ ), а коэффициент расширения снижен с фиксированного значения  $6\times$  до диапазона  $4\text{--}6\times$ . Такая модификация уменьшает число параметров на 40–60

Для head-части LiteMobileNet2D предусмотрено усиление регуляризации: добавлен слой Dropout с вероятностью 0,3 после финальной свертки  $\text{Conv}1 \times 1$ , а классификатор упрощен до линейного слоя из 30 нейронов, соответствующих числу классов в задаче. Это решение исключает избыточные вычисления и снижает риск переобучения.

Сравнение оригинальной архитектуры MobileNetV2 и модифицированной LiteMobileNet2D представлено в таблице 2.

Таблица 2. Сравнение LiteMobileNet2D с оригинальным MobileNetV2

| Компонент              | MobileNetV2 (оригинал)                                   | LiteMobileNet2D (авторский)                                 |
|------------------------|----------------------------------------------------------|-------------------------------------------------------------|
| Входные каналы         | 3 (RGB)                                                  | 1 (градации серого)                                         |
| Коэффициент расширения | Фиксированный $6\times$                                  | Динамический ( $4\text{--}6\times$ )                        |
| Активация              | ReLU6                                                    | SiLU + ReLU6                                                |
| Регуляризация          | L2-норма                                                 | Dropout                                                     |
| Stem-блок              | Conv3 $\times$ 3 (stride=2) + расширение                 | Conv3 $\times$ 3 (stride=2) $\rightarrow$ SiLU              |
| Базовое расширение     | $6\times$                                                | $4\text{--}6\times$ (вариативно)                            |
| Глубина боков          | 19 слоев                                                 | 6 инвертированных остаточных блоков                         |
| Head-часть             | Conv1 $\times$ 1 $\rightarrow$ Pool $\rightarrow$ Linear | Conv1 $\times$ 1 $\rightarrow$ Dropout $\rightarrow$ Linear |

Адаптация MobileNetV2 в архитектуре LiteMobileNet2D позволила достичь высокой энергоэффективности без значимых потерь точности. Использование упрощенных инвертированных блоков и активации SiLU обеспечило качественное выделение временно-частотных паттернов ЭЭГ при значительном сокращении числа параметров. Добавление Dropout на завершающем этапе повысило устойчивость модели к переобучению, что особенно важно для работы с небольшими экспериментальными датасетами. LiteMobileNet2D может служить основой для разработки портативных BCI-систем, требующих низкого энергопотребления и обработки сигналов в реальном времени.

### 3.3. Оптимизация ResNet для анализа ЭЭГ-спектрограмм

Архитектура ResNet (Residual Network), изначально разработанная для задач компьютерного зрения, стала одним из наиболее значимых достижений в области глубокого обучения благодаря введению остаточных блоков (ResBlocks) с короткими соединениями (skip-connections). Эти блоки позволяют эффективно решать проблему затухания градиентов и обеспечивают стабильное обучение даже в очень глубоких сетях. Высокая результативность ResNet подтверждена в широком спектре приложений – от классификации изображений в ImageNet до семантической сегментации, что сделало ее эталонной архитектурой для последующих модификаций.

В данной работе ResNet была адаптирована под специфику ЭЭГ-спектрограмм в виде архитектуры LiteResNet2D. В отличие от оригинала, где в начальном stem-блоке используется свертка с ядром  $7 \times 7$ , в LiteResNet2D применяются компактные фильтры  $3 \times 3$ , что сокращает вычислительные затраты и количество параметров. Это особенно важно для анализа биомедицинских сигналов с ограниченными по размеру датасетами.

Ядро архитектуры составляют остаточные блоки, сохраняющие принцип оригинальной ResNet: комбинация проекционного слоя (Conv2d  $1 \times 1$ ) и двух последовательных сверточных операций  $3 \times 3$  с нормализацией и активацией ReLU. Существенным отличием LiteResNet2D является стратегия даунсэмплинга: параметр stride=2 используется в каждом ResBlock, а не только в первом блоке слоя, как в исходной версии. Такой подход обеспечивает быстрое уменьшение пространственной размерности и ускоряет выделение высокоуровневых признаков, но требует баланса между компактностью и сохранением информативных деталей.

Завершающая часть сети (head) включает адаптивный средний пулинг (AdaptiveAvgPool2d), операцию выравнивания (Flatten), слой Dropout и два последовательных линейных преобразования. В отличие от базовой ResNet, где после глобального пулинга используется единственный классификационный слой, в LiteResNet2D добавлен промежуточный полносвязный слой с Dropout, что повышает регуляризацию и снижает риск переобучения. Экспериментальные результаты показали, что предложенная конфигурация улучшает обобщающую способность модели при умеренной вычислительной нагрузке.

Сравнение ключевых параметров оригинальной ResNet и LiteResNet2D представлено в таблице 3.

**Таблица 3.** Сравнение LiteResNet2D с оригинальной ResNet

| Компонент      | ResNet (оригинал)            | LiteResNet2D (авторский)     |
|----------------|------------------------------|------------------------------|
| Глубина        | 18–152 слоев                 | 3 блока (6 сверточных слоев) |
| Начальный слой | Conv7 × 7 + MaxPool          | Conv3 × 3 + MaxPool          |
| Базовые каналы | 64 → 512                     | 32 → 256                     |
| Downsampling   | В первом блоке каждого этапа | В каждом ResBlock (stride=2) |
| Head-часть     | AvgPool → Linear             | AvgPool → Dropout → 2 Linear |

Адаптация ResNet в виде архитектуры LiteResNet2D показала эффективность для анализа ЭЭГ-спектрограмм, сохранив ключевые преимущества оригинальной модели и одновременно снизив вычислительную сложность. Использование компактных сверток  $3 \times 3$  и агрессивного даунсэмплинга позволило достичь оптимального баланса между скоростью обработки и сохранением информативных признаков. Введение дополнительного полносвязного слоя с Dropout повысило устойчивость модели к переобучению и улучшило ее обобщающую способность на малых биомедицинских выборках. LiteResNet2D можно рассматривать как перспективное решение для задач классификации ЭЭГ в условиях ограниченных ресурсов, что делает ее применимой для разработки энергоэффективных и портативных нейроинтерфейсов.

#### 4. РЕЗУЛЬТАТЫ ЭКСПЕРИМЕНТОВ С ГЛУБОКИМ ОБУЧЕНИЕМ И КЛАССИФИКАЦИЕЙ

В экспериментальной части исследования оценивалась практическая эффективность трех адаптированных архитектур – SimpleAlexNet, LiteMobileNet2D и LiteResNet2D – при классификации спектрограмм ЭЭГ. Основное внимание уделялось динамике обучения и способности моделей сохранять устойчивость при ограниченном объеме данных.

Сравнение проводилось по ключевым показателям: F1-мера, точность классификации, устойчивость кривых валидации и характер сходимости. Такой подход позволил выявить различия в чувствительности моделей к шумам, а также их способность адаптироваться к низкоразмерным входным данным ( $32 \times 32$  пикселя).

Для обеспечения корректности анализа все модели обучались в одинаковых условиях: датасет – 3720 образцов, тренировочная выборка – 75 %, число эпох – 100, оптимизатор Adam, скорость обучения –  $1e-4$ , размер батча – 16.

Каждая продемонстрированная архитектура проявила специфические преимущества, что позволяет рассматривать их как взаимодополняющие решения для различных сценариев применения в нейроинтерфейсах.

Для оценки эффективности трех модифицированных архитектур проведено сравнение по ключевым метрикам качества и устойчивости (см. Рис. 2).

Анализ включал как итоговые значения F1-меры и точности, так и динамику обучения в процессе оптимизации. Такой подход позволяет не только зафиксировать конечные результаты, но и проследить, как разные сети ведут себя на протяжении всего цикла обучения: насколько быстро они достигают плато, подвержены ли переобучению и демонстрируют ли стабильность на валидационных данных.

На Рис. 3 показана динамика изменения валидационной точности (Accuracy) по эпохам для трех архитектур. Из результатов видно, что SimpleAlexNet быстрее всего выходит на стабильный уровень, однако ее точность ограничивается относительно невысокими значениями. LiteMobileNet2D обеспечивает более плавный и устойчивый рост, достигая лучших результатов при меньшем риске переобучения. Наибольшую эффективность показывает LiteResNet2D,




Рис. 2. График динамики валидационной точности (Accuracy) во времени.




Рис. 3. Сравнительный барчарт по итоговым метрикам Accuracy и F1-score.

которая стабильно превосходит конкурирующие модели и сохраняет тенденцию роста даже на поздних стадиях обучения.

Сравнительный анализ трех модифицированных архитектур показал, что каждая из них обладает специфическими преимуществами. SimpleAlexNet отличается быстрым выходом на рабочие значения метрик, что делает ее подходящей для прототипирования и сценариев с огра-

ническим временем обучения, однако итоговая точность остается умеренной. LiteMobileNet2D продемонстрировала оптимальный баланс между скоростью работы и качеством классификации, что делает ее перспективной для внедрения в портативные нейроинтерфейсы и энергоограниченные устройства. Наиболее высокие результаты достигнуты архитектурой LiteResNet2D, которая обеспечила максимальные значения точности и F1-меры при сохранении устойчивости обучения. Таким образом, именно LiteResNet2D можно рассматривать как наиболее перспективное решение для задач автоматической типологизации ЭЭГ в рамках данного исследования.

## ЗАКЛЮЧЕНИЕ

Настоящее исследование показало, что адаптация сверточных архитектур под низкоразмерные частотно-временные представления ЭЭГ обеспечивает высокую точность типологической классификации при умеренных вычислительных затратах. Сравнение SimpleAlexNet, LiteMobileNet2D и LiteResNet2D выявило различия в траекториях обучения и устойчивости к шуму. LiteResNet2D, благодаря residual-блокам и целенаправленному даунсэмплингу, лучше других извлекает иерархию признаков и достигает максимальных итоговых метрик ( $F1 \approx 0.91$ ) при стабильных валидационных кривых. LiteMobileNet2D демонстрирует наилучшее соотношение точность/ресурсы за счет облегченных инвертированных блоков и эффективной регуляризации, что делает ее предпочтительной для портативных и энергоограниченных систем реального времени. SimpleAlexNet, имея минимальную параметрическую сложность, обеспечивает быстрый выход на плато и может служить базовой “рабочей лошадкой” в задачах первичной типологизации и экспресс-развертываний.

Концептуально важным результатом является подтверждение гипотезы о связи между свойствами сигнала и подбором архитектуры. Распределение ошибок и скорость сходимости зависят от локальной временной структуры ритмов; следовательно, устойчивость моделей повышается при использовании архитектур, чувствительных к соответствующим спектральным паттернам. Практически это выражается в рекомендациях: (i) для более “переходных” окон и выраженных начальных эффектов – ResNet-образные схемы; (ii) для энергоэффективной обработки длительных стабильных сегментов – облегченные MobileNet-варианты; (iii) для прототипирования и ограниченных выборок – компактные AlexNet-модификации.

Ограничения исследования включают умеренный размер выборки и фокус на четырех фронтальных/фронтально-височных отведениях; необходимы расширенные когортные данные, оценка межсессионной стабильности и проверка в дополнительных парадигмах (двигательные/когнитивные задачи). Методологически перспективны: интеграция механизмов внимания и трансформеров для учета дальних зависимостей; доменная адаптация и перенос между субъектами/сессиями; self-supervised и few-shot схемы для снижения потребности в разметке. Важным направлением остается формализация карты “свойство сигнала → тип сети” как инженерного руководства, включающего критерии выбора архитектуры по спектральной плотности, стабильности ритмов и требованиям к энергопотреблению. В целом полученные результаты подтверждают продуктивность подхода типологизации ЭЭГ на основе согласованных с сигналом CNN-архитектур и задают основу для переносимых нейроинтерфейсов и стандартизованных протоколов оценки.

## СПИСОК ЛИТЕРАТУРЫ

1. Benabid A.L. et al. An exoskeleton controlled by an epidural wireless brain-machine interface in a tetraplegic patient: a proof-of-concept demonstration. *Lancet Neurol.* 2019 Dec. 18(12):1112-1122. doi: 10.1016/S1474-4422(19)30321-7.

2. Zheng L., Sun S., Zhao H., Pei W., Chen H., Gao X., Zhang L. and Wang Y. A Cross-Session Dataset for Collaborative Brain-Computer Interfaces Based on Rapid Serial Visual Presentation. *Front. Neurosci.* 2020, 14:579469. doi: 10.3389/fnins.2020.579469.
3. Bhattacharyya, S., Valeriani, D., Cinel, C. et al. Anytime collaborative brain-computer interfaces for enhancing perceptual group decision-making. *Sci Rep.*, 2021, 11, 17008. <https://doi.org/10.1038/s41598-021-96434-0>.
4. Foros Ø., Hansen B. and Vergé T. Co-operative Investment by Downstream Rivals: Network Sharing in Telecom Markets. *J. Regul. Econ.*, 2023, 64, pp. 34–47/ <https://doi.org/10.1007/s11149-023-09462-1>.
5. Yang D., Nguyen T-H., Chung W-Y. A Bipolar-Channel Hybrid Brain-Computer Interface System for Home Automation Control Utilizing Steady-State Visually Evoked Potential and Eye-Blink Signals. *Sensors*, 2020, 20(19):5474. <https://doi.org/10.3390/s20195474>.
6. Albaqami H, Hassan G.M., Datta A. Automatic Detection of Abnormal EEG Signals Using WaveNet and LSTM. *Sensors* (Basel), 2023, Jun 27; 23(13):5960. doi: 10.3390/s23135960.
7. Halme, H.L., Parkkonen, L. Across-subject offline decoding of motor imagery from MEG and EEG. *Sci Rep.*, 8, 10087 (2018). <https://doi.org/10.1038/s41598-018-28295-z>.
8. Wei X., Ortega P., Faisal A.A. Inter-subject Deep Transfer Learning for Motor Imagery EEG Decoding // *arXiv preprint*. no. 2103.05351, 2021.
9. Han D.-K., Musellim S., Kim D.-Y., Jeong J.-H. Confidence-Aware Subject-to-Subject Transfer Learning for Brain-Computer Interface [Электронный ресурс] // *arXiv preprint*. no. 2112.09243, 2022.
10. Tao T., Yi X., Xiaorong G., Shangkai G. Chirp-modulated visual evoked potential as a generalization of steady state visual evoked potential. *Journal of neural engineering*, 2011, 9(1), 016008. DOI: 10.1088/1741-2560/9/1/016008.
11. Turovsky Y., Wolf D., Meshcheryakov R., Iskhakova A.: Dynamics of Frequency Characteristics of Visually Evoked Potentials of Electroencephalography During the Work with Brain-Computer Interfaces. In: Prasanna, S.R.M., Karpov, A., Samudravijaya, K., Agrawal, S.S. (eds) *Speech and Computer. SPECOM 2022. Lecture Notes in Computer Science*, vol 13721. Springer, Cham (2022). doi: 10.1007/978-3-031-20980-2\_57.
12. Huang G., Zhao Z., Zhang S., Hu Z., Fan J., Fu M., Chen J., Xiao Y., Wang J. and Dan G. Discrepancy between inter- and intra-subject variability in EEG-based motor imagery brain-computer interface: Evidence from multiple perspectives. *Front. Neurosci.*, 2023, 17:1122661. doi: 10.3389/fnins.2023.1122661.
13. Xu L., Xu M., Ke Y., An X., Liu S. and Ming D. Cross-Dataset Variability Problem in EEG Decoding With Deep Learning. *Front. Hum. Neurosci.*, 2020, 14:103. doi: 10.3389/fnhum.2020.00103.
14. Wu S., Bhadra K., Giraud A.L., Marchesotti S. Adaptive LDA Classifier Enhances Real-Time Control of an EEG Brain-Computer Interface for Decoding Imagined Syllables. *Brain Sci.*, 2024, Feb 21; 14(3):196. doi: 10.3390/brainsci14030196.
15. Giles J., Ang K.K., Phua K.S. and Arvaneh M. A Transfer Learning Algorithm to Reduce Brain-Computer Interface Calibration Time for Long-Term Users. *Front. Neuroergon.*, 2022, 3:837307. doi: 10.3389/fnrgo.2022.837307.
16. Вольф Д.А., Туровский Ю.А., Мещеряков Р.В., Исаков А.Ю. Программа “Автокодировщик сигнала ЭЭГ”. Свидетельство о государственной регистрации программы для ЭВМ № 2023618452 РФ; Заявл. 23.05.2023.
17. Исакова А.О., Мещеряков Р.В., Вольф Д.А., Туровский Я.А. Автокодировщик электрической активности головного мозга человека // Вестник Южно-Уральского государственного университета. Серия: Математика. Механика. Физика, 2023, Т. 15, № 1. , С. 34–42. DOI 10.14529/mmph230104.

## Adapted Convolutional Architecture for Typological Analysis of Sensorimotor EEG Spectrograms

D. A. Wolf, Y. A. Turovsky, S. B. Galina, R. R. Galin

The article explores the classification of electroencephalographic signals through their time-frequency representations using adapted convolutional neural networks. The study shows that targeted architectural modifications significantly enhance the performance of automated EEG analysis. This reflects the principle “the signal shapes the network,” emphasizing that model design must align with the spectral features and rhythm dynamics of neural activity. EEG signals were converted into spectrogram-like time-frequency maps and processed as image inputs for training. To match the data properties, classical CNN architectures were reconfigured: some streamlined for efficiency, others tailored to single-channel input, and others extended with residual blocks and advanced regularization. Experimental evaluation confirmed consistent learning stability across all variants, with specific advantages for each: LiteResNet2D provided the highest accuracy, LiteMobileNet2D offered optimal performance for low-resource environments, and SimpleAlexNet2D facilitated prototyping and rapid exploration. The results underline the necessity of adapting convolutional architectures to EEG properties as a foundation for robust, generalizable classification systems. This strategy enables scalable tools suitable for applications in neuroscience research, brain-computer interfaces, and clinical diagnostics.

**KEYWORDS:** electroencephalography, biometric, deep learning, convolutional neural networks, sensorimotor rhythms, neuro-interface