

# Машинное обучение в распознавании нативных и искусственно сгенерированных ЭЭГ<sup>1</sup>

К.Д. Русаков\*, Я.А. Туровский\*, Е.А. Киселев\*\*

\* *Институт проблем управления им. В.А. Трапезникова РАН*

\*\* *ФГБОУВО «Воронежский государственный университет»*

Поступила в редколлегию 25.06.2024 г. Принята 1.10.2024 г.

**Аннотация**—В статье представлен комплексный подход к анализу электроэнцефалографических (ЭЭГ) сигналов полученных как с человеческого мозга так и искусственно синтезированных при использовании методов машинного обучения. Основное внимание уделено предварительной обработке данных, включая нормализацию и фильтрацию сигналов, а также применению различных методов извлечения признаков, таких как быстрое преобразование Фурье и мел-частотные кепстральные коэффициенты. Проведён сравнительный анализ точности классификации с использованием логистической регрессии, случайного леса, градиентного бустинга и рекуррентной нейронной сети LSTM. Особое внимание уделено влиянию параметров фильтрации на точность классификации. Результаты показали, что фильтрация и корректная настройка параметров модели существенно повышают точность классификации ЭЭГ сигналов, обеспечивая разделение реального и модельного пула ЭЭГ. Представленные результаты и обсуждение могут служить основой для дальнейших исследований в области анализа и обработки биомедицинских сигналов.

**КЛЮЧЕВЫЕ СЛОВА:** ЭЭГ сигналы, машинное обучение, нормализация, фильтрация, быстрое преобразование Фурье, мел-частотные кепстральные коэффициенты, логистическая регрессия, случайный лес, градиентный бустинг, LSTM, классификация.

DOI: 10.53921/18195822\_2024\_24\_3\_190

## 1. ВВЕДЕНИЕ

Электроэнцефалография (ЭЭГ) является одним из ключевых методов мониторинга и анализа мозговой активности благодаря своей неинвазивности, доступности и высокой временной разрешающей способности. Точное и своевременное распознавание паттернов ЭЭГ имеет важное значение для диагностики и лечения различных неврологических заболеваний, а также для развития технологий мозг-компьютерных интерфейсов. В последние годы методы машинного обучения и глубокого обучения становятся всё более популярными для анализа ЭЭГ данных, поскольку они способны выявлять сложные нелинейные закономерности в данных, недоступные традиционным статистическим методам. Подобные подходы нашли своё применение в различных областях, включая медицинскую диагностику и разработку интерфейсов мозг-компьютер [1, 12]. В тоже время возникает необходимость в совершенствовании верификации методов цифровой обработки ЭЭГ, что существенно затруднено невозможностью получить ЭЭГ сигнал с полностью известными свойствами. Нативное ЭЭГ представляет собой продукт нелинейного взаимодействия большого числа осцилляторов, что существенно затрудняет реализуемую на ранних этапах верификации метода цифровой обработки сигналов качество работы указанного метода. Таким образом становится очевидным необходимость

<sup>1</sup> Работа выполнена при поддержке РФФ, проект № 23-19-00664 (<https://rscf.ru/project/23-19-00664/>).

синтеза искусственных сигналов с заданными свойствами, но при этом, максимально схожими с ЭЭГ [13].

Существующие методы обработки и классификации ЭЭГ данных включают широкий спектр подходов, от традиционных машинных методов до современных глубоких нейронных сетей. В исследовании [2] авторы исследовали применение глубоких нейронных сетей для классификации ЭЭГ сигналов, демонстрируя превосходство сверточных нейронных сетей (CNN) над другими моделями в плане эффективности обучения и точности. Использование пространственно-временной информации позволило значительно улучшить результаты классификации. В работе [3] представили интеграцию элементов машинного обучения на базе ЭЭГ в системе eHealth IoT с использованием библиотеки TensorFlow. Основное внимание было уделено разработке устройств, управляемых артефактами ЭОГ, для интерпретации движений глаз. М. Н. Rafiei и авторы в [4] предложили использование самосупервизируемого обучения (SSL) для обработки ЭЭГ данных, что позволяет улучшить точность моделей при ограниченном количестве размеченных данных. Их исследование показало, что SSL может эффективно использоваться для объединения различных наборов данных, что увеличивает общую точность и снижает переобучение моделей [14].

Авторы в работе [5] провели эксперимент по выявлению индивидуально-типологических особенностей распознавания реальных и модельных сигналов, что подчеркивает важность данной темы для улучшения качества синтетических ЭЭГ данных и снижения рисков получения ложных моделей. В работе [6] использовали методы машинного обучения для предсказания возраста на основе ЭЭГ данных. Их исследование продемонстрировало высокую точность моделей, основанных на архитектуре EEGNet, и подчеркнуло важность использования качественных и разнообразных наборов данных для тренировки моделей. Несмотря на значительные успехи, достигнутые в области анализа и классификации ЭЭГ данных с помощью методов машинного обучения, данная тема остаётся до конца не исследованной. Большинство существующих исследований сосредоточены на улучшении точности классификации или внедрении новых архитектур глубокого обучения, но многие аспекты, такие как влияние предварительной обработки данных, выбор оптимальных параметров фильтрации и сравнение различных моделей машинного обучения, всё ещё требуют дальнейшего изучения [15]. Кроме того, получение ЭЭГ с заданными свойствами является сложной и нетривиальной задачей. Точность и надежность анализа мозговой активности напрямую зависят от качества и характеристик исходных данных. В реальных условиях ЭЭГ сигналы могут быть подвержены различным видам шумов и артефактов, что затрудняет их последующую обработку и интерпретацию. Следовательно, возникает необходимость разработки методов, которые не только обеспечивают получение ЭЭГ с требуемыми свойствами, но и позволяют создавать временные последовательности, имитирующие ЭЭГ сигналы с заданными характеристиками [16]. Такие синтетические данные могут быть крайне полезны для тестирования и валидации алгоритмов машинного обучения, что позволит улучшить точность и эффективность анализа реальных ЭЭГ данных.

Таким образом, актуальность данного исследования определяется необходимостью разработки и совершенствования моделей синтеза искусственных ЭЭГ. В условиях увеличения применения искусственных данных в различных областях нейрофизиологии и медицинских исследований, становится критически важным обеспечить высокое качество синтезируемых сигналов. Одним из главных вызовов является разработка методов, позволяющих эффективно различать искусственные и нативные ЭЭГ [17]. Это необходимо для выявления возможных дефектов в процессе синтеза, которые могут привести к созданию ложных моделей и, как следствие, к некорректным выводам. Таким образом, улучшение методов синтеза и анализа ЭЭГ данных способствует повышению надежности и точности результатов исследований в области.

Одним из ключевых направлений исследований в области анализа ЭЭГ является автоматическое обнаружение диагностических показателей и ритмов мозга. В работе [23] из ИРЭ им. В.А. Котельникова РАН представлен новый подход к автоматическому детектированию показателей отсроченной ишемии головного мозга после субарахноидального кровоизлияния на основе анализа хребтов вейвлет-спектрограмм. Данный метод позволяет более точно идентифицировать эпилептиформную активность и предсказывать развитие ишемии путем анализа межканальной синхронизации. Это исследование подчеркивает важность использования вейвлет-спектрограмм для детального анализа динамики ЭЭГ сигналов, что является значительным вкладом в улучшение диагностики и лечения неврологических заболеваний. Другие значимые работы включают исследования [24] также из ИРЭ им. В.А. Котельникова РАН, в которых рассматриваются методы многомасштабного корреляционного анализа для обнаружения и мониторинга ритмов коры головного мозга. Автор представляет усовершенствованную технику вычисления частотно-временных представлений на основе аналитических спектров, ориентированную на обнаружение нейронной активности в широких частотных диапазонах. В отличие от классического спектрального анализа, эти методы позволяют эффективно мониторить колебательную активность нейронов, что важно для глубокого понимания функционирования мозга и развития методов лечения различных неврологических расстройств.

Целью данного исследования является анализ возможности разделения нативных (реальных) и искусственно сгенерированных ЭЭГ сигналов с помощью методов машинного обучения. Исследование включает предварительную обработку данных, извлечение признаков и классификацию. Нативные ЭЭГ сигналы представляют собой записи мозговой активности, полученные напрямую от человека с использованием неинвазивных электродов. Эти сигналы характеризуются высокой сложностью и вариативностью из-за нелинейных взаимодействий большого числа нейронных осцилляторов. Искусственные ЭЭГ сигналы создаются для контролируемого внесения изменений и тестирования различных алгоритмов обработки и анализа сигналов. Синтетические данные позволяют точно оценить эффективность предложенных методов и моделей, что сложно сделать при использовании только реальных данных из-за их сложной и нелинейной природы. Таким образом, синтетические ЭЭГ сигналы способствуют проведению более точных и воспроизводимых экспериментов, что улучшает методы диагностики и лечения неврологических заболеваний, а также развитие технологий мозг-компьютерных интерфейсов. Особое внимание уделено методам предварительной обработки и фильтрации сигналов для обеспечения точного распознавания и интерпретации паттернов мозговой активности. Практическое применение данных исследований включает разработку более точных диагностических инструментов и методов лечения, а также создание надежных систем мозг-компьютерного интерфейса, что может значительно повысить качество жизни пациентов с неврологическими расстройствами.

## 2. МАТЕРИАЛЫ И МЕТОДЫ

В рамках исследования ЭЭГ основной целью было разделение данных на два сверхкласса: сигналы, полученные от человеческого мозга, и сигналы, сгенерированные компьютером. Дополнительно изучалось влияние фильтрации на точность распознавания этих классов и определялись наиболее эффективные архитектуры нейронных сетей для классификации машинно-генерированных ЭЭГ. Для моделирования постсинаптических импульсов, формирующих ЭЭГ, используются парные функции Гаусса, имитирующие возбуждающие постсинаптические потенциалы (ВПСП) и тормозные постсинаптические потенциалы (ТПСП) [18]. Эти функции сдвинуты друг относительно друга по времени, направлены в разные стороны, имеют одинаковую ширину, но разные амплитуды. Итоговый сигнал ЭЭГ (рис. 1) является суперпозицией большого количества постсинаптических импульсов с разной амплитудой и временем возник-

новения, а также белого шума. Время возникновения постсинаптических импульсов подчиняется равномерному распределению, а амплитуда – нормальному закону с нулевым средним. После генерации модельный сигнал подвергается дискретизации и нормировке [19].

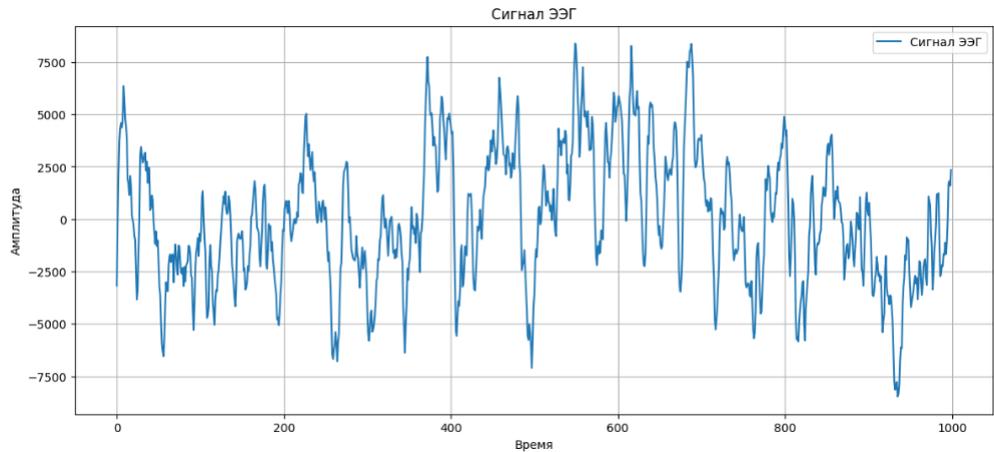


Рис. 1. Итоговый сигнал ЭЭГ.

Исследование началось с предварительной подготовки данных: нормализацию и фильтрацию. Нормализация выполнялась методом стандартной нормализации, при котором каждое значение в данных ЭЭГ трансформировалось так, чтобы среднее значение равнялось нулю, а стандартное отклонение — единице [20]. Однако, первоначальные попытки классификации данных после только нормализации показали низкую точность, что указывало на необходимость дополнительной обработки данных. Следующим шагом была применена фильтрация с помощью полосового фильтра Баттерворта [7]. Фильтр Баттерворта известен своей характеристикой плоской амплитудно-частотной характеристики в полосе пропускания, что делает его подходящим для фильтрации сигналов, таких как ЭЭГ, где важно минимизировать искажения. Частоты среза и порядок фильтра подбирались экспериментально для оптимального удаления шумов и нежелательных частот [8], сохраняя при этом существенные характеристики сигналов. Фильтрация описывается передаточной функцией:

$$H(f) = \frac{1}{1 + \left(\frac{f}{f_c}\right)^{2n}}$$

где  $f_c$  — частота среза, а  $n$  — порядок фильтра. Применение фильтрации значительно улучшило точность классификации, демонстрируя важность этого этапа в обработке сигналов ЭЭГ [21].

Дополнительно были протестированы различные методы извлечения признаков: Быстрое Преобразование Фурье (англ.: FFT) и Мел-частотные кепстральные коэффициенты (англ.: MFCC). FFT был выбран в качестве основного метода из-за его способности выделять частотные компоненты сигнала, что оказалось полезным для дальнейшей классификации. FFT позволяет преобразовывать временные ряды сигналов в частотную область, выделяя основные частотные компоненты, которые могут быть полезны для классификации [22]. Это особенно актуально для анализа ЭЭГ сигналов, где различные паттерны активности мозга проявляются на определённых частотах. MFCC широко используются в обработке речевых сигналов и также могут быть полезны для анализа ЭЭГ сигналов, так как они могут захватывать важные акустические признаки.

## 3. КЛАССИФИКАЦИЯ ЭЭГ ДАННЫХ

Для задачи классификации были испытаны различные модели машинного обучения, включая логистическую регрессию, случайный лес, градиентный бустинг и LSTM [9]. Каждая из этих моделей имеет свои преимущества и недостатки в зависимости от специфики данных и задач [10]. Были рассмотрены данные как в объединении по типу генерации (человек против машины), так и в разбиении на 10 классов для более детального анализа. В первую очередь была использована модель нейронной сети LSTM (рис. 2) для классификации данных на основе различных настроек фильтра. Данные были разделены на обучающий и тестовый наборы, где 20% данных были выделены для тестирования. Для корректной обработки несбалансированных данных была применена техника взвешивания примеров.

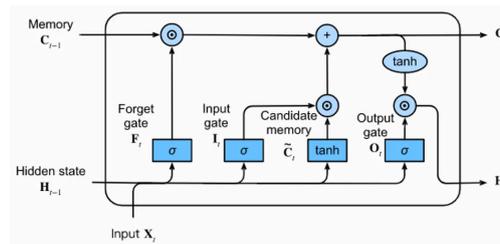


Рис. 2. Архитектура LSTM.

Веса были заданы в соответствии с пропорцией классов в обучающем наборе: классу, представленному меньшим количеством данных, был присвоен более высокий вес. Это особенно полезно в контексте использования взвешенных методов выборки или прямого взвешивания в функции потерь. Формула для расчета веса для каждого класса:

$$w_i = \frac{kN}{n_i}$$

где:

- $w_i$  — вес для класса  $i$ ,
- $N$  — общее количество примеров в обучающем наборе,
- $k$  — количество классов,
- $n_i$  — количество примеров в классе  $i$ .

Эта формула уравнивает вклад каждого класса в функцию потерь, присваивая более высокий вес классам с меньшим количеством образцов. В вашем случае, где два класса могут быть сильно несбалансированы, использование такой схемы взвешивания позволяет компенсировать меньшее представление одного из классов, увеличивая его влияние на процесс обучения. Модель LSTM была спроектирована с одним слоем LSTM и последующим полносвязным слоем. В LSTM слой входят параметры: размер входных данных (англ.: *input\_size*), размер скрытых слоев (англ.: *hidden\_size*). Процесс обучения включал несколько эпох, в каждой из которых выполнялась итерация по мини-батчам обучающего набора. Для каждого батча проводилось обнуление градиентов, выполнение прямого распространения, расчет потерь, обратное распространение градиента и обновление весов модели. В качестве функции потерь использовалась кросс-энтропия, а для оптимизации — Adam с небольшим шагом обучения (рис. 3).

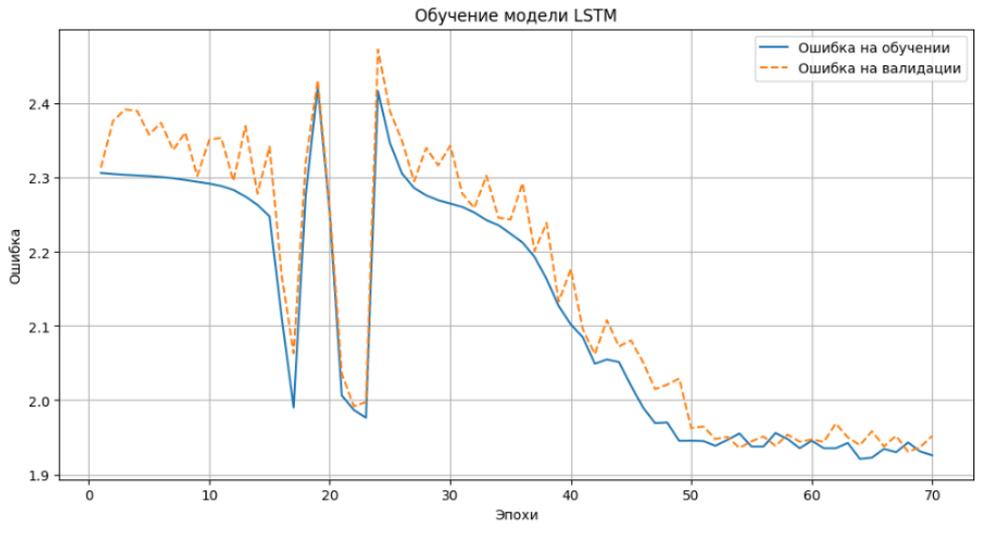


Рис. 3. График обучения LSTM

Описательная статистика результатов точности модели показала следующее: средняя точность составила 78.71%, со стандартным отклонением 22.03%. Минимальное значение точности достигло 13.10%, в то время как максимальное — 95.80%. В рамках комплексного анализа данных ЭЭГ были исследованы и протестированы различные модели машинного обучения для определения их эффективности в классификации двух сверхклассов: данных, полученных от человеческого мозга, и сигналов, сгенерированных машинами. Помимо LSTM, использовались логистическая регрессия, случайный лес и градиентный бустинг. Эти модели были выбраны из-за их различных подходов к обработке данных и способности обрабатывать большие объемы информации с различной степенью точности и сложности.

Таблица 1. Сравнительные результаты распознавания нативных и сгенерированных ЭЭГ различными моделями машинного обучения.

Модель	Средняя точность (%)	Стандартное отклонение (%)	Минимальная точность (%)	Максимальная точность (%)
LSTM	78.71	22.03	13.1	95.8
Логистическая регрессия	90.35	0.61	89.45	91.45
Случайный лес	90.84	1.92	86.65	92.9
Градиентный бустинг	90.58	0.81	89.25	91.7

Статистическая обработка данных для каждой модели показала следующие результаты: логистическая регрессия продемонстрировала среднюю точность 90.35% с минимальной вариацией (стандартное отклонение 0.61%), что указывает на её стабильность в предсказаниях. Случайный лес показал среднюю точность 90.84%, но с более высоким стандартным отклонением 1.92%, что может свидетельствовать о чувствительности модели к выборке данных. Градиентный бустинг зарегистрировал среднюю точность 90.58% с низким стандартным отклонением 0.81%. В сравнении, LSTM, применяемая первоначально, показала среднюю точность 78.71% с высоким стандартным отклонением 22.03%. Эти результаты указывают на потенциально высокую чувствительность LSTM к параметрам модели и к настройкам данных, однако она также продемонстрировала способность достигать высокой максимальной точности до 95.80%, что свидетельствует о возможностях этой модели к высоким достижениям при правильной настройке параметров. В контексте этого исследования, несмотря на более высокую стабильность и немного лучшую среднюю точность логистической регрессии, случайного леса и градиентного бустинга по сравнению с LSTM, последняя показывает существенно более высокий по-

тенциал максимальной точности. Это делает LSTM особенно ценной для задач, где требуется не просто высокая средняя точность, но и способность модели адаптироваться к сложным шаблонам данных для достижения исключительных результатов в отдельных случаях. Таким образом, выбор модели для конкретного применения должен учитывать не только среднюю точность, но и другие факторы, такие как потенциал к максимальной точности и стабильность предсказаний, особенно в приложениях, где ошибки могут иметь серьезные последствия.

#### 4. АНАЛИЗ РЕЗУЛЬТАТОВ

В рамках исследования был проведен тщательный анализ влияния параметров фильтрации на точность классификации данных ЭЭГ. Четыре основных параметра — частота дискретизации (англ.: *fs*), нижний порог фильтрации (англ.: *lowcut*), верхний порог фильтрации (англ.: *highcut*) и порядок фильтра (англ.: *order*) — были варьированы в широких пределах для изучения их эффектов на результаты моделирования. Конкретные значения для каждого параметра были выбраны в следующих пределах: Частота дискретизации: [300.0, 400.0, 500.0] Гц. Нижний порог фильтрации: [0.3, 0.4, 0.5, 0.6, 0.7] Гц. Верхний порог фильтрации: [40.0, 50.0, 60.0, 70.0] Гц. Порядок фильтра: [1, 2, 3, 4, 5, 6, 7, 8, 9, 10].

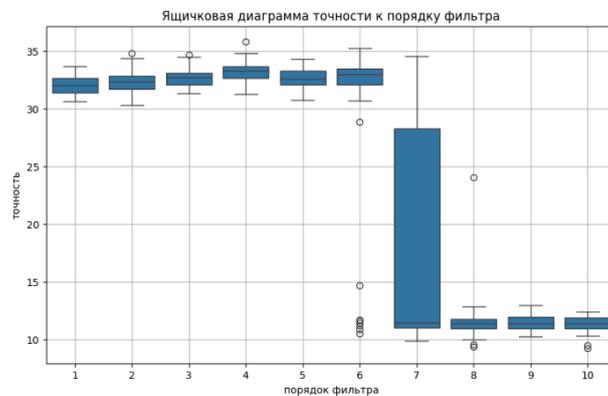


Рис. 4. Ящичковые диаграммы точности от порядка

Такая вариация параметров позволяет провести исчерпывающее исследование их эффектов на результаты моделирования, обеспечивая оптимальную настройку фильтрации для повышения точности классификации ЭЭГ сигналов. Особенно примечательно распределение точности в зависимости от порядка фильтра, что можно увидеть на графике (рис. 4). Анализ показывает, что при порядках фильтра от 1 до 6 точность классификации находится в высоком диапазоне, близком к 90%, что указывает на эффективность этих настроек фильтра для модели LSTM в задаче классификации ЭЭГ данных. Однако с увеличением порядка фильтра до 7 и выше наблюдается значительное увеличение разброса результатов точности — от 40% до 90%. Это может указывать на то, что более высокие порядки фильтра могут вносить излишние искажения в данные или удалять значимые частоты, что затрудняет классификацию. Анализ корреляционной матрицы данных ЭЭГ (рис. 5) с использованием коэффициента Спирмана позволяет нам оценить взаимосвязи между различными параметрами фильтрации и их влияние на точность классификации. Значимые корреляции показывают, что изменения *fs* имеют минимальное воздействие на результаты, что указывает на устойчивость модели к изменениям в частоте дискретизации. Затем было рассмотрено воздействие нижнего и верхнего порогов фильтрации. Анализ показал, что мелкие корректировки в значениях *lowcut* и *highcut* могут привести к небольшому улучшению точности. В частности, незначительное увеличение *lowcut*

и highcut способствовало повышению точности, что предполагает, что исключение некоторых низкочастотных и высокочастотных шумов может улучшить качество сигналов ЭЭГ для анализа.

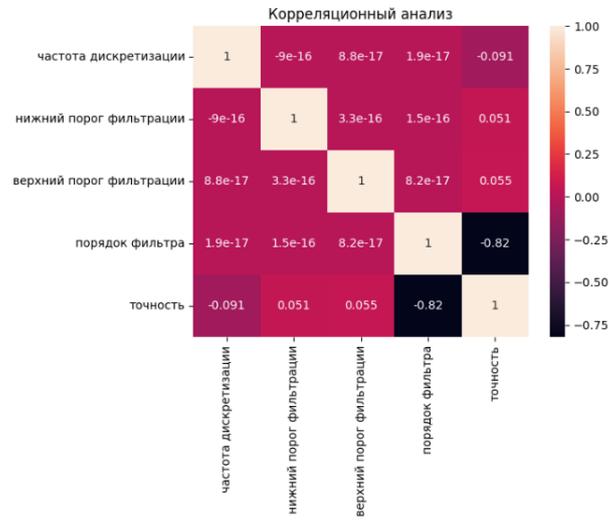


Рис. 5. Матрица корреляции признаков

Особенно значительное воздействие на точность классификации оказал порядок фильтра. В ходе экспериментов было обнаружено, что с увеличением порядка фильтра точность сначала увеличивалась, достигая пика при определенных значениях, после чего начинала снижаться. Это явление можно объяснить тем, что более высокий порядок фильтра обеспечивает более строгую фильтрацию, что может быть полезным до определенного предела, после которого начинается потеря важной информации в сигнале. Корреляционный анализ, проведенный для дополнительной оценки этих наблюдений, подтвердил сильную отрицательную связь между порядком фильтра и точностью, особенно при высоких значениях порядка, что еще раз подчеркивает необходимость тщательного подбора этого параметра. В рамках статистической обработки данных ЭЭГ была выполнена оценка важности признаков с использованием дерева решений, чтобы определить, как различные параметры фильтрации влияют на точность классификации. Использовалась следующая методика: 1. Была создана таблица с параметрами фильтрации и соответствующими значениями точности. Данные разделены на обучающую и тестовую выборки в соотношении 70% на 30%, чтобы обеспечить достаточное количество данных для обучения модели и при этом оставить независимый набор для оценки её производительности. 2. Использовалась модель регрессора дерева решений, обученная на тренировочной выборке. Эта модель была выбрана из-за её способности эффективно обрабатывать как числовые, так и категориальные данные, а также из-за возможности интерпретировать результаты через визуализацию важности признаков. 3. После обучения модели были сделаны предсказания на тестовой выборке, и точность этих предсказаний была измерена с помощью метрики средней абсолютной ошибки (англ.: MAE), которая составила приблизительно 1.299. Это значение MAE указывает на уровень ошибки в предсказаниях модели в единицах измерения целевой переменной (точности классификации).

Анализ важности признаков (рис. 6) показал следующее:

- Порядок фильтра имел наибольшую важность (86.56%), что подтверждает результаты предыдущих анализов, указывающих на существенное влияние этого параметра на качество классификации данных.
- Влияние частоты среза составило примерно 6.82%, что также подчеркивает важность выбора адекватного верхнего порога среза.
- Параметры *lowcut* и *fs* показали более низкую значимость (3.34% и 3.16% соответственно), что может указывать на их меньшее воздействие на точность модели.

Для оценки распределения точности по классам использовались следующие параметры и методы обработки данных. Исходные данные ЭЭГ были преобразованы в числовой массив и подвергнуты полосовой фильтрации с использованием фильтра Баттерворта. Частота дискретизации составляла 500 Гц, нижний порог фильтрации был установлен на 0.5 Гц, а верхний порог на 50 Гц. После фильтрации данные были нормализованы и преобразованы с помощью FFT для извлечения признаков.

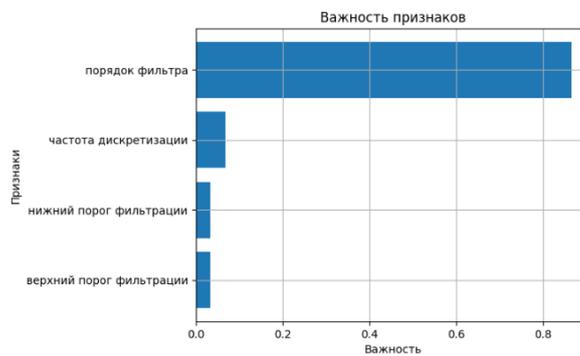


Рис. 6. График важности признаков

Извлеченные признаки были преобразованы в тензоры PyTorch и подготовлены для использования в модели LSTM. Обучение модели проводилось на выборке, состоящей из 10000 сигналов ЭЭГ (1000 нативных и 9000 искусственно сгенерированных), разделенных на обучающую и тестовую выборки в соотношении 80:20. С учетом дисбаланса классов была применена балансировка. Модель обучалась в течение 200 эпох с использованием оптимизатора Adam и шагом обучения 0.0001. Для каждой выборки данных были рассчитаны метрики точности (англ.: precision), полноты (англ.: recall) и F1-меры (англ.: f1-score) для каждого класса отдельно.

Таблица 2. Параметры качества модели LSTM при распознавании нативных и сгенерированных ЭЭГ.

Класс	Precision	Recall	F1-score	Support
Нативные ЭЭГ	0.97	1.00	0.98	199
Искусственные ЭЭГ	1.00	0.97	0.98	201

Результаты классификации показывают, что модель достигает высокой точности для обоих классов. Средняя точность для класса "Нативные ЭЭГ" составила 97%, полнота – 100%, а F1-мера – 98%. Для класса "Искусственные ЭЭГ" точность составила 100%, полнота – 97%, а F1-мера – 98%. Для наглядности были построены диаграммы, показывающие распределение метрик по классам, что позволяет визуально оценить эффективность классификации для каждого класса.

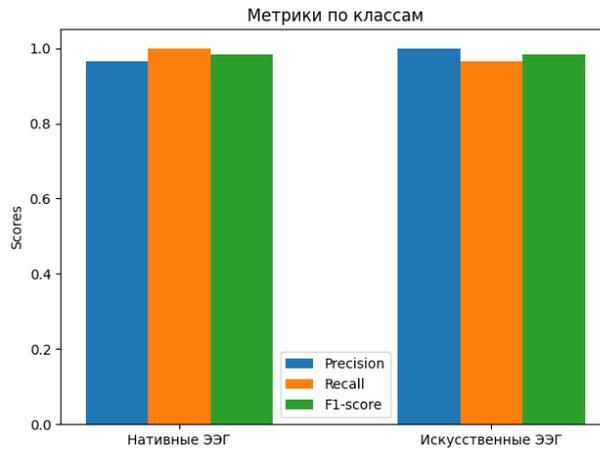


Рис. 7. Диаграмма распределения метрик по классам

Корреляционный анализ с использованием коэффициента Спирмана позволил нам более точно оценить влияние параметров фильтрации на точность классификации, исключив менее значимые взаимосвязи. Подобный подход использовался в ряде предыдущих исследований для улучшения точности классификации [11]. Для изучения влияния параметров фильтрации на точность классификации ЭЭГ сигналов были рассчитаны коэффициенты корреляции Спирмана и соответствующие  $p$ -значения. Результаты показали, что корреляции между параметрами фильтрации и точностью классификации имеют разные уровни значимости.

Корреляционная матрица Спирмана продемонстрировала следующие результаты: порядок фильтра (*order*) имеет наибольшую отрицательную корреляцию с точностью классификации ( $-0.63$ ), что подтверждает значительное влияние этого параметра на результаты моделирования.  $p$ -значение для этой корреляции составляет  $1.21 \times 10^{-66}$ , что свидетельствует о её высокой статистической значимости. Это указывает на то, что изменения в порядке фильтра существенно влияют на точность классификации, и данная зависимость не является случайной.

В отличие от этого, другие параметры, такие как частота дискретизации, нижний порог фильтрации и верхний порог фильтрации, показали менее выраженные корреляции с точностью классификации. Корреляция между частотой дискретизации и точностью составила  $-0.096$  с  $p$ -значением  $0.0189$ , но влияние этого параметра на точность значительно меньше по сравнению с порядком фильтра.

Нижний и верхний пороги фильтрации показали слабые положительные корреляции с точностью ( $0.054$  и  $0.050$  соответственно).

Результаты анализа подчеркивают критическую роль правильной настройки параметров фильтрации, особенно порядка фильтра, для оптимизации точности распознавания ЭЭГ. Высокая важность параметра *order* подкрепляет необходимость тщательного выбора этого параметра при проектировании фильтров для обработки сигналов ЭЭГ.

Для верификации предложенных методов были проведены тщательные эксперименты и валидирование на различных наборах данных. Валидация включала сравнение предложенных моделей с существующими методами: логистическая регрессия, случайный лес и градиентный бустинг. Для оценки качества подхода использовались метрики точности, чувствительности и специфичности. Проведен статистический анализ результатов, который продемонстрировал значимость улучшений, обеспечиваемых нашими методами. Корреляции между различными метриками также были тщательно исследованы, чтобы подтвердить надежность полученных данных. Кроме того, подробно описаны все настройки экспериментов и параметры моделей,

что позволяет другим исследователям воспроизвести наши эксперименты и подтвердить полученные выводы. Результаты показали, что правильная настройка параметров моделей и тщательная фильтрация данных значительно повышают точность классификации ЭЭГ сигналов, обеспечивая разделение реальных и искусственных данных.

## 5. ЗАКЛЮЧЕНИЕ

На основе проведённого исследования данных ЭЭГ можно сформулировать следующие ключевые выводы по поставленным задачам:

1. Исследование демонстрирует, что различные архитектуры нейронных сетей: LSTM, логистическая регрессия, случайный лес и градиентный бустинг способны эффективно разделять ЭЭГ данные на два сверхкласса — сигналы, полученные от человеческого мозга, и машинно-генерированные сигналы. Хотя модели показали различную степень точности, все они демонстрируют потенциал для выполнения этой задачи, подчеркивая важность выбора подходящей модели в зависимости от конкретных требований приложения.
2. Анализ показал, что параметры фильтрации: частота дискретизации ( $fs$ ), нижний (*lowcut*) и верхний (*highcut*) пороги, а также порядок фильтра (*order*) оказывают значительное влияние на точность классификации. Особенно критичным является порядок фильтра, который, как было обнаружено, влияет на точность обратно пропорционально: увеличение порядка снижает точность классификации. Это подчеркивает необходимость тщательной настройки фильтрационных параметров для оптимизации результатов.
3. Среди исследованных архитектур LSTM выделилась своей способностью достигать высокой максимальной точности, особенно в задачах, где требуется обработка сложных временных последовательностей данных. Однако логистическая регрессия, случайный лес и градиентный бустинг также показали хорошие результаты, особенно с точки зрения стабильности и предсказуемости производительности. Это указывает на то, что выбор архитектуры должен базироваться на конкретных целях исследования, природе данных и требованиях к точности и стабильности.

В результате исследования была достигнута поставленная цель — анализ возможности разделения нативных (реальных) и искусственно сгенерированных ЭЭГ сигналов с использованием методов машинного обучения. Результаты показывают, что предложенные методы успешно справляются с этой задачей, подтверждая достижение цели. Выбор различных архитектур нейронных сетей и анализ параметров фильтрации позволили выявить оптимальные подходы для классификации ЭЭГ данных.

Проведённое исследование имеет значительные практические применения, включая улучшение методов диагностики и лечения неврологических заболеваний, а также развитие технологий мозг-компьютерных интерфейсов. Синтетические ЭЭГ сигналы, использованные в исследовании, продемонстрировали свою ценность для тестирования и валидации алгоритмов машинного обучения, что подтверждает возможность проведения более точных и воспроизводимых экспериментов. Это, в свою очередь, способствует созданию более точных диагностических инструментов и методов лечения, а также надежных систем мозг-компьютерного интерфейса, что может значительно повысить качество жизни пациентов с неврологическими расстройствами.

Исследование подтверждает, что классификация ЭЭГ данных — сложная, но решаемая задача с использованием современных методов машинного обучения. Понимание и оптимизация параметров фильтрации играют ключевую роль в улучшении производительности моделей. Различные архитектуры нейронных сетей могут быть эффективно использованы для дости-

жения заданных исследовательских целей, но выбор конкретной модели должен учитывать специфические требования задачи и характеристики данных.

## СПИСОК ЛИТЕРАТУРЫ

1. Li, Gen, Lee, Chang, Jung, Jason, Youn, Young Chul, and Camacho, David. Deep learning for EEG data analytics: A survey. *Concurrency and Computation: Practice and Experience*, 2019, vol. 32, 10.1002/cpe.5199.
2. Li, Z. "Electroencephalography Signal Analysis and Classification Based on Deep Learning,"2020 5th International Conference on Information Science, Computer Technology and Transportation (ISCTT), Shenyang, China, 2020, pp. 119-125. DOI: 10.1109/ISCTT51595.2020.00029.
3. Pap, I. A., Oniga, S., Alexan, A. "Machine Learning EEG Data Analysis For eHealth IoT System,"2020 IEEE International Conference on Automation, Quality and Testing, Robotics (AQTR), Cluj-Napoca, Romania, 2020, pp. 1-4. DOI: 10.1109/AQTR49680.2020.9129966.
4. Rafiei, M. H., Gauthier, L. V., Adeli, H., Takabi, D. "Self-Supervised Learning for Electroencephalography,"IEEE Transactions on Neural Networks and Learning Systems, vol. 35, no. 2, pp. 1457-1471, Feb. 2024. DOI: 10.1109/TNNLS.2022.3190448.
5. Туровский, Я. А., Тищенко, В. А., Киселев, Е. А., Индивидуально-типологические особенности распознавания реальных и модельных сигналов электроэнцефалограммы. *Эргодизайн*, 4(22), с. 405-412. 2023. DOI: 10.30987/2658-4026-2023-4-405-412. EDN: ВХРХЕМ.
6. Sinha, G. et al. "Machine Learning Methods for Electroencephalogram-Based Age Prediction,"2023 IEEE SENSORS, Vienna, Austria, 2023, pp. 1-4. DOI: 10.1109/SENSORS56945.2023.10324895.
7. Электроэнцефалография: руководство / М. В. Александров, Л. Б. Иванов, С. А. Лытаев [и др.] / под ред. М. В. Александрова. — 3-е изд., перераб. и доп. — Санкт-Петербург: СпецЛит, 2020. — 224 с.
8. Blankertz, Benjamin, Tomioka, Ryota, Lemm, Steven, Kawanabe, Motoaki, and Müller, Klaus-Robert. Optimizing Spatial filters for Robust EEG Single-Trial Analysis. *Signal Processing Magazine, IEEE*, 2008, vol. 25, pp. 41-56. 10.1109/MSP.2008.4408441.
9. Mozer, Mike. "A Focused Backpropagation Algorithm for Temporal Pattern Recognition". *Complex Systems*, 1989.
10. Hashmi, Anam, Khan, Bilal, and Farooq, Omar. A Comparative Study of Machine Learning Algorithms for EEG Signal Classification. *Signal & Image Processing : An International Journal*, 2021, vol. 12, pp. 37-50. 10.5121/sipij.2021.12603.
11. Al-Nafjan, A. Feature selection of EEG signals in neuromarketing. *PeerJ Comput Sci.*, 2022 Apr 26;8:e944. DOI: 10.7717/peerj-cs.944. PMID: 35634118; PMCID: PMC9138093.
12. Kamil Gatfan, S. A Review on Deep Learning For Electroencephalogram Signal Classification. *Journal of Al-Qadisiyah for Computer Science and Mathematics*, 2024, vol. 16, no. 1, Comp. 137–151. DOI: <https://doi.org/10.29304/jqcs.2024.16.11453>.
13. Bashivan, P., Rish, I., Yeasin, M., and Codella, N. Learning Representations from EEG with Deep RecurrentConvolutional Neural Networks. arXiv preprint arXiv:1511.06448, 2015.
14. Craik, A., He, Y., and Contreras-Vidal, J. L. Deep learning for electroencephalogram (EEG) classification tasks: a review. *Journal of Neural Engineering*, 2019, vol. 16, no. 3, 031001. DOI: 10.1088/1741-2552/ab0ab5.
15. Roy, Y., Banville, H., Albuquerque, I., Gramfort, A., Falk, T. H., and Faubert, J. Deep learning-based electroencephalography analysis: a systematic review. *Journal of Neural Engineering*, 2019, vol. 16, no. 5, 051001. DOI: 10.1088/1741-2552/ab260c.
16. Lawhern, V. J., Solon, A. J., Waytowich, N. R., Gordon, S. M., Hung, C. P., and Lance, B. J. EEGNet: a compact convolutional neural network for EEG-based brain-computer interfaces. *Journal of Neural Engineering*, 2018, vol. 15, no. 5, 056013. DOI: 10.1088/1741-2552/aace8c.

17. Schirrmeister, R. T., Springenberg, J. T., Fiederer, L. D., Glasstetter, M., Eggensperger, K., Tangermann, M., ... and Ball, T. Deep learning with convolutional neural networks for EEG decoding and visualization. *Human brain mapping*, 2017, vol. 38, no. 11, pp. 5391-5420. DOI: 10.1002/hbm.23730.
18. Mullen, T. R., Kothe, C. A., Chi, Y. M., Ojeda, A., Kerth, T., Makeig, S., ... and Cauwenberghs, G. Real-time neuroimaging and cognitive monitoring using wearable dry EEG. *IEEE Transactions on Biomedical Engineering*, 2015, vol. 62, no. 11, pp. 2553-2567. DOI: 10.1109/TBME.2015.2481482.
19. Cohen, M. X. Analyzing neural time series data: theory and practice. MIT press, 2017. DOI: <https://doi.org/10.7551/mitpress/9609.001.0001>.
20. He, H., Wu, D. Transfer Learning for Brain-Computer Interfaces: A Euclidean Space Data Alignment Approach. *IEEE Trans Biomed Eng.*, 2020 Feb;67(2):399-410. DOI: 10.1109/TBME.2019.2913914. Epub 2019 Apr 29. PMID: 31034407.
21. Delorme, A., and Makeig, S. EEGLAB: an open source toolbox for analysis of single-trial EEG dynamics including independent component analysis. *Journal of neuroscience methods*, 2004, vol. 134, no. 1, pp. 9-21. DOI: 10.1016/j.jneumeth.2003.10.009.
22. Huang, G. B., Zhu, Q. Y., and Siew, C. K. Extreme learning machine: theory and applications. *Neurocomputing*, 2006, vol. 70, no. 1-3, pp. 489-501. DOI: 10.1016/j.neucom.2005.12.126.
23. Обухов, Ю.В., Кершнер, И.А., и Синкин, М.В. Новый подход к автоматизированному обнаружению диагностических показателей отсроченной ишемии головного мозга после субарахноидального кровоизлияния в данных длительного ЭЭГ мониторинга. *Журнал Радиоэлектроники*, 2022, № 10. DOI: 10.30898/1684-1719.2022.10.11.
24. Анциперов, В.Е. Обнаружение ритмов головного мозга человека на основе корреляции аналитических спектров ЭЭГ в основных диапазонах частот. *Институт радиотехники и электроники им. В.А. Котельникова РАН*, 2014.

## Machine Learning in Recognition of Native and Artificially Generated EEG

K.D. Rusakov, Ya.A. Turovsky, E.A. Kiselev

This paper presents a comprehensive approach to the analysis of electroencephalographic (EEG) signals obtained from both the human brain and artificially synthesized using machine learning methods. The main focus is on data preprocessing, including signal normalization and filtering, as well as the application of various feature extraction methods, such as Fast Fourier Transform and Mel-Frequency Cepstral Coefficients. A comparative analysis of classification accuracy using logistic regression, random forest, gradient boosting, and recurrent neural network LSTM is conducted. Special attention is given to the influence of filtering parameters on classification accuracy. The results show that filtering and proper tuning of model parameters significantly improve the accuracy of EEG signal classification, ensuring the separation of real and synthetic EEG pools. The presented results and discussion can serve as a basis for further research in the field of biomedical signal analysis and processing.

**KEYWORDS:** EEG signals, machine learning, normalization, filtering, Fast Fourier Transform, Mel-Frequency Cepstral Coefficients, logistic regression, random forest, gradient boosting, LSTM, classification.