

МИНОБРНАУКИ РОССИИ
ФЕДЕРАЛЬНОЕ ГОСУДАРСТВЕННОЕ БЮДЖЕТНОЕ
ОБРАЗОВАТЕЛЬНОЕ УЧРЕЖДЕНИЕ ВЫСШЕГО ОБРАЗОВАНИЯ
«САРАТОВСКИЙ НАЦИОНАЛЬНЫЙ ИССЛЕДОВАТЕЛЬСКИЙ
ГОСУДАРСТВЕННЫЙ УНИВЕРСИТЕТ ИМЕНИ Н.Г. ЧЕРНЫШЕВСКОГО»

Кафедра электроники, колебаний и волн

**Разработка метода анализа полисомнографических данных для
выделения различных стадий сна**

АВТОРЕФЕРАТ МАГИСТЕРСКОЙ РАБОТЫ

студента 2 курса 2231 группы

направления

03.04.03 «Радиофизика»

института физики

Евстропова Максима Аркадьевича

Научный руководитель
доцент кафедры электроники,
колебаний и волн, к.ф.-м.н.

Е.Н. Егоров, 08.06.2026
подпись, дата

Егоров Е.Н.

Заведующий кафедрой
электроники, колебаний и волн
к.ф.-м.н., доцент

С.В. Гришин, 08.06.2026
дата, подпись

С.В. Гришин

Саратов 2026 год

Введение

Сон является одной из фундаментальных физиологических потребностей человека. Нарушения сна, такие как бессонница, синдром обструктивного апноэ сна, нарколепсия и другие расстройства, оказывают негативное влияние на качество жизни, повышают риск развития сердечно-сосудистых, эндокринных и нервно-психических заболеваний.

Золотым стандартом диагностики нарушений сна является полисомнография – комплексная запись физиологических сигналов (электроэнцефалограммы, электроокулограммы, электромиограммы, дыхательных движений, электрокардиограммы) в течение ночного сна. Ключевым этапом анализа полисомнографических данных является стадирование сна – классификация 30-секундных эпох записи на стадии бодрствования, небыстрого (N1, N2, N3) и быстрого (REM) сна. Традиционно это выполняется вручную квалифицированными сомнологами в соответствии с рекомендациями Американской академии медицины сна (AASM). Однако ручное стадирование обладает рядом существенных недостатков: высокая трудоёмкость (анализ одной ночной записи занимает 2–4 часа), субъективность (межэкспертное согласие составляет лишь 80–85%), невозможность воспроизведения результатов и утомляемость эксперта.

С развитием методов искусственного интеллекта и машинного обучения появилась возможность создания автоматизированных систем классификации стадий сна. Особый интерес представляют методы, основанные на обработке одного канала электроэнцефалограммы (ЭЭГ), поскольку они потенциально применимы для создания портативных систем домашнего мониторинга сна, не требующих сложного оборудования и присутствия медицинского персонала.

Однако существующие методы не всегда демонстрируют достаточную точность, чувствительны к шумам и артефактам, а также плохо обобщаются на данные разных пациентов. Это определяет *актуальность* разработки

новых, более эффективных и устойчивых методов анализа полисомнографических данных для выделения стадий сна.

Целью настоящей работы является разработка метода анализа полисомнографических данных для выделения различных стадий сна на основе вейвлет-преобразования и нейросетевых классификаторов.

Для достижения поставленной цели были решены следующие **задачи**:

1. Проведен обзор математических методов анализа медицинских данных с применением систем искусственного интеллекта. Выделены основные подходы к классификации стадий сна.
2. Разработан алгоритм предобработки полисомнографических сигналов, включающий фильтрацию и устранение артефактов.
3. Реализован метод извлечения признаков на основе вейвлет-пакетного разложения ЭЭГ.
4. Создана и обучена нейронная сеть для отнесения 30-секундных эпох к одной из стадий сна.

Работа состоит из следующих основных разделов:

1. Обзор методов автоматической классификации стадий сна по сигналам ЭЭГ;
2. Экспериментальное исследование и разработка методов классификации стадий сна по сигналам ЭЭГ;
3. Обучение нейронной сети и оптимизация её параметров для классификации стадий сна.

Основное содержание работы

В первом разделе работы проведён систематический обзор подходов к решению задачи стадирования сна. Как уже отмечалось во Введении, ЭЭГ является одним из наиболее информативных и широко используемых методов исследования функционального состояния головного мозга [1]. Автоматическая классификация стадий сна и обнаружение дремоты являются важнейшими задачами современной биомедицинской обработки сигналов.

Эволюция методов прослеживается от традиционных подходов машинного обучения, основанных на двухэтапной процедуре (извлечение заранее заданных признаков и последующая классификация), до глубоких нейронных сетей, автоматически извлекающих иерархические представления из сырых сигналов. Среди классических методов широкое распространение получили спектральные (мощность в частотных диапазонах, спектральные отношения), вейвлет-признаки (энергия и энтропия коэффициентов различных масштабов) [2]. Критическим этапом в данных подходах остаётся предобработка, включающая фильтрацию и удаление артефактов.

Проведённый анализ позволяет сделать вывод, что современные методы автоматической классификации стадий сна и дремоты эволюционируют в сторону усложнения моделей и повышения интерпретируемости. Перспективными направлениями являются создание устойчивых к индивидуальным вариациям алгоритмов, адаптация для работы в носимых устройствах реального времени, а также разработка методов, обеспечивающих доверие врачей-клиницистов за счёт объяснимости решений. Обзор подтверждает высокий потенциал гибридных архитектур, что обуславливает выбор направления исследований в рамках настоящей магистерской работы.

Во втором разделе работы описывается экспериментальная база, процедура предобработки сигналов, метод извлечения информативных признаков на основе вейвлет-пакетного преобразования и архитектура

нейросетевого классификатора, разработанного для автоматического распознавания стадий сна по одноканальной ЭЭГ [3].

Исходным материалом послужили полисомнографические записи ночного сна 72 добровольцев, выполненные в ходе клинического исследования. Частота дискретизации составляла 200 Гц. Все записи размечены врачом-сомнологом по стандартам R&K на стадии бодрствования, REM, N1, N2 и N3. Для последующего анализа был выбран сигнал отведения С3-А2, которое, согласно литературным данным, обладает наибольшей диагностической ценностью для классификации стадий сна [4]. Записи сегментированы на 30-секундные эпохи (по 6000 отсчётов), каждой эпохе присвоена соответствующая экспертная метка.

Для удаления артефактов и низкочастотного дрейфа ЭЭГ подвергалась полосовой фильтрации с помощью фильтра Баттерворта 4-го порядка в диапазоне 0,5–62,5 Гц [5, 6]. Выбор данного диапазона обусловлен тем, что основная физиологически значимая активность при сне сосредоточена в дельта-, тета-, альфа- и бета-диапазонах, а составляющие выше относятся к шумам.

Для анализа нестационарных ЭЭГ-сигналов использовано вейвлет-пакетное разложение (Wavelet Packet Transform, WPT), которое, в отличие от классического преобразования Фурье, даёт совместное время-частотное представление и позволяет локализовать особенности сигнала, такие как сонные веретёна и К-комплексы. В качестве материнского вейвлета выбран вейвлет Добеши четвёртого порядка (db4), обладающий хорошей локализацией в обеих областях и компактностью. Уровень декомпозиции установлен равным пяти: при частоте дискретизации 200 Гц это обеспечивает частотное разрешение 6,25 Гц, что достаточно для разделения основных ритмов ЭЭГ. Для каждой 30-секундной эпохи вычислялись энергии коэффициентов в 32 поддиапазонах; для снижения размерности признакового пространства использовались только первые 10 низкочастотных

поддиапазонов, в которых сосредоточена наиболее релевантная информация о стадиях сна.

Поскольку вейвлет-признаки уже представляют собой компактное и информативное описание сигнала, для классификации выбрана полносвязная нейронная сеть (многослойный перцептрон). Предложенная архитектура содержит четыре полносвязных слоя: входной слой размерности 10, два скрытых слоя по 512 нейронов с функцией активации ReLU и выходной слой с числом нейронов, равным количеству классов - 5. Выбор полносвязной сети обоснован тем, что извлечённые признаки уже агрегируют локальные зависимости.

Для обучения использован оптимизатор Adam с начальной скоростью обучения 0,001, который адаптивно подбирает шаг для каждого параметра, обеспечивая быструю сходимость. Для борьбы с дисбалансом классов применён взвешенный случайный семплер: веса классов обратно пропорциональны их частоте встречаемости, что позволяет повысить вклад редких стадий. Обучение проводилось в течение 1000 эпох с разделением выборки на обучающую (80 %) и тестовую (20 %); каждые 50 батчей вычислялась точность на валидационном подмножестве для контроля сходимости и предотвращения переобучения.

Весь алгоритм реализован на языке Python с использованием библиотек PyTorch (для построения и обучения нейросети), NumPy, SciPy (для фильтрации), PyWavelets (для вейвлет-преобразования), Matplotlib и Seaborn (для визуализации). Программный комплекс выполняет следующие этапы: загрузку и синхронизацию сырых записей, фильтрацию, извлечение вейвлет-признаков, формирование датасетов с балансировкой, обучение модели и построение графиков точности и функции потерь.

Таким образом, разработанная методика объединяет классические методы спектрально-временного анализа с современными подходами глубокого обучения, что позволяет достичь высокой точности классификации

при использовании лишь одного отведения ЭЭГ и компактного набора признаков.

В третьей главе представлены результаты экспериментального исследования разработанного алгоритма автоматической классификации стадий сна. Проведён цикл вычислительных экспериментов, направленных на оценку влияния глубины сети, числа нейронов в скрытых слоях и скорости обучения на точность классификации и вычислительную эффективность.

Исследование выполнено на полисомнографических записях 72 пациентов (отведение С3-А2, частота дискретизации 200 Гц). Исходные сигналы подвергнуты фильтрации (0,5–50 Гц) и сегментации на 30-секундные эпохи. Для каждой эпохи вычислялись энергии коэффициентов вейвлет-пакетного разложения (вейвлет Добеши 4-го порядка, уровень декомпозиции 5) в 10 низкочастотных поддиапазонах, что формировало входной вектор признаков размерности 10. Выборка случайным образом разделялась на обучающую (80 %) и тестовую (20 %) части. Обучение проводилось на 1000 эпох с оптимизатором Adam (начальная скорость обучения 0,001) и функцией потерь – кросс-энтропия. Все эксперименты выполнялись на персональном компьютере с GPU-ускорением.

Исследовались многослойные перцептроны с двумя и тремя скрытыми слоями, каждый с одинаковым числом нейронов (32, 64, 128, 256, 512). Активация – ReLU, выходной слой – 5 нейронов (по числу стадий: бодрствование, N1, N2, N3, REM). Оценивались точность на обучающей и тестовой выборках, а также полное время обучения.

С увеличением числа нейронов с 32 до 512 тестовая точность монотонно возрастала с 79,3 % до 92,6 %, а время обучения – с 43,3 до 74,1 секунды. Точность на обучающей выборке при этом достигала 97,5 %, что указывает на хорошую аппроксимирующую способность.

Добавление третьего скрытого слоя при 512 нейронах не повысило тестовую точность (92,0 % против 92,6 %), но увеличило время обучения до 92,3 секунды. При меньшем числе нейронов (128 и 256) тестовая точность

оказалась ниже, чем для двухслойной сети. Это позволяет заключить, что для данной задачи увеличение глубины не даёт преимуществ и может приводить к переобучению при ограниченном объёме данных.

Для трехслойной сети была опробована повышенная начальная скорость (0,01). При малом числе нейронов (32–64) наблюдался рост точности на обучении, однако тестовая точность существенно не изменилась, а при 512 нейронах даже снизилась до 88,9 %, что объясняется нестабильностью градиентного спуска. Таким образом, скорость 0,001 признана оптимальной.

На основе полученных данных выявлено, что:

- Увеличение числа нейронов до 256 даёт основной прирост точности; дальнейшее наращивание до 512 улучшает результат незначительно (менее 3 %), но удваивает вычислительные затраты.
- Глубина сети более трёх слоёв нецелесообразна – дополнительный слой не повышает точность и замедляет обучение.
- Оптимальным компромиссом между точностью и быстродействием является архитектура с двумя скрытыми слоями по 512 нейронов: точность на тестовой выборке достигает 92,6 % при времени обучения около 74 секунд.

Полученный результат (92,6 %) сопоставим с показателями более сложных глубоких моделей (свёрточных и рекуррентных сетей) на аналогичных открытых базах данных, которые демонстрируют точность в диапазоне 83–97 % в зависимости от числа классов и отведений. При этом предложенный подход отличается низкой вычислительной сложностью и простотой реализации, что делает его перспективным для применения в портативных системах мониторинга сна, где ограничены ресурсы по энергопотреблению и производительности.

Таким образом, экспериментально подтверждена эффективность комбинации вейвлет-пакетных признаков и полносвязной нейросети с

оптимизированной архитектурой для автоматического стадирования сна по одноканальной ЭЭГ. Достигнутая точность находится на уровне экспертного согласия и является достаточной для практических приложений.

Заключение

В дипломной работе решена актуальная задача – разработка метода автоматической классификации стадий сна по одноканальной ЭЭГ с использованием вейвлет-преобразования и полносвязной нейронной сети. Актуальность обусловлена распространённостью нарушений сна, трудоёмкостью и субъективностью ручного стадирования, отсутствием доступных автоматизированных систем для клинической практики и домашнего мониторинга.

В ходе работы решены следующие задачи:

- 1) Проведён обзор современных методов анализа медицинских данных с применением систем искусственного интеллекта.** Проанализированы основные подходы к классификации стадий сна – от традиционных (методы опорных векторов, случайный лес) до гибридных архитектур, объединяющих вейвлет-анализ, свёрточные и рекуррентные сети. Установлено, что существующие методы не всегда обеспечивают достаточную точность для трудноразличимых стадий (N1 и REM) и чувствительны к индивидуальным различиям пациентов.
- 2) Разработан алгоритм предобработки полисомнографических сигналов.** Предложена фильтрация полосовым фильтром Баттерворта 4-го порядка (0,5–62,5 Гц), что позволяет подавить высокочастотные шумы и сохранить физиологические ритмы.
- 3) Реализован метод извлечения признаков на основе вейвлет-пакетного разложения.** Для каждой 30-секундной эпохи вычислялись энергии коэффициентов вейвлет-пакетного разложения (вейвлет Добеши четвёртого порядка, уровень декомпозиции 5). Из 32 поддиапазонов отобраны 10 наиболее низкочастотных, содержащих основную информацию о стадиях сна.

- 4) **Создана и обучена нейронная сеть для классификации стадий сна.** Разработана полносвязная сеть с переменным числом скрытых слоёв (2 или 3) и количеством нейронов (32–512). Используются ReLU-активация, кросс-энтропия, оптимизатор Adam (скорость 0,001). Для борьбы с дисбалансом классов применён взвешенный сэмплер.
- 5) **Проведена экспериментальная оценка метода.** Исследовано влияние числа слоёв, нейронов и скорости обучения на точность классификации и время вычислений. Установлено, что оптимальная конфигурация – сеть с тремя слоями (входной, два скрытых, выходной) и 512 нейронами. Данная конфигурация достигла тестовой точности **92,6 %** при времени обучения 74 секунды. Более глубокие сети (4 слоя) не дали преимущества, а повышение скорости обучения до 0,01 снизило стабильность.

Практическая значимость – разработанный программный комплекс может применяться для автоматического стадирования сна, снижения нагрузки на врачей-сомнологов, а также для создания портативных систем домашнего мониторинга сна ввиду низкой вычислительной сложности.

Достоверность результатов обеспечивается использованием стандартных протоколов предобработки, многократными экспериментами, сопоставимостью с опубликованными данными.

Таким образом, **цель работы достигнута** – разработан эффективный метод классификации стадий сна по одноканальной ЭЭГ, сочетающий вейвлет-пакетное извлечение признаков и полносвязную нейронную сеть, демонстрирующий высокую точность (92,6 %) при низкой вычислительной сложности, что подтверждает его перспективность для применения в сомнологии и биомедицинской инженерии.

Список литературы

1. Зенков Л. Р. Клиническая электроэнцефалография (с элементами эпилептологии) / Л. Р. Зенков. — 5-е изд. — Москва : МЕДпресс-информ, 2012. — 356 с.
2. Addison P. S. Wavelet transforms and the ECG: a review // *Physiological Measurement*. — 2005. — Vol. 26, № 5. — P. R155–R199.
3. Belakhdar I., Kaaniche W., Djmel R., Ouni B. A comparison between ANN and SVM classifier for drowsiness detection based on single EEG channel // *2nd International Conference on Advanced Technologies for Signal and Image Processing (ATSIP'2016)*. — Monastir, Tunisia: IEEE, 2016. — P. 1–4.
4. Khalighi S., Sousa T., Santos J.M., Nunes U. ISRUC-Sleep: a comprehensive public dataset for sleep researchers // *Computer Methods and Programs in Biomedicine*. – 2016. – Vol. 124. – P. 180–192.
5. Al-Qazzaz N. K., Sabir M. K., Ali S. H. B. M., et al. 3.2. Preprocessing Stage // *Bio-protocol*. — 2021.
6. Aqueel A., Farooq O., Khan Y. U. Sleep Apnea Event Detection Using EEG Band Entropy Features and Machine Learning // *2023 International Conference on Recent Advances in Electrical, Electronics & Digital Healthcare Technologies (REEDCON)*. — IEEE, 2023. — P. 699–704.