

МИНОБРНАУКИ РОССИИ

Федеральное государственное бюджетное образовательное учреждение
высшего образования

«САРАТОВСКИЙ НАЦИОНАЛЬНЫЙ ИССЛЕДОВАТЕЛЬСКИЙ
ГОСУДАРСТВЕННЫЙ УНИВЕРСИТЕТ ИМЕНИ Н.Г.ЧЕРНЫШЕВСКОГО»

Кафедра информатики и программирования

**ИСПОЛЬЗОВАНИЕ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ В
ЗАДАЧЕ КЛАССИФИКАЦИИ СТАДИЙ СНА ПО СИГНАЛАМ ЭКГ
АВТОРЕФЕРАТ БАКАЛАВРСКОЙ РАБОТЫ**

студента 4 курса 441 группы

направления 02.03.03 Математическое обеспечение и администрирование
информационных систем

факультета компьютерных наук и информационных технологий

Самойчук Натальи Борисовны

Научный руководитель:

старший преподаватель

Лапшева Е.Е.

подпись, дата

Зав. кафедрой:

к.ф.-м.н., доцент

Огнева М. В.

подпись, дата

Саратов 2025

ВВЕДЕНИЕ

Актуальность темы. Сон является неотъемлемой частью нормальной жизнедеятельности человека. От качества сна зависит продолжительность жизни и деятельность во время бодрствования. В современном мире все больше людей осознают важность качественного сна для здоровья и общего благополучия. Однако, недостаточно спать долго, необходимо делать это правильно, чтобы организм успевал отдыхать и восстанавливаться[1].

Важным аспектом автоматического анализа сна является использование сигналов электрокардиографии (ЭКГ) для классификации его стадий. Полисомнография (ПСГ) считается золотым стандартом в исследованиях сна, но она требует сложного оборудования и не всегда удобна для длительного мониторинга. В этом контексте ЭКГ представляет собой перспективную альтернативу, так как её проще регистрировать, а изменения в работе сердца тесно связаны с вегетативной регуляцией, которая варьируется в зависимости от стадии сна.

Цель бакалаврской работы: реализация автоматического классификатора стадий сна с использованием методов машинного обучения.

Для достижения цели необходимо выполнить **следующие задачи:**

1. изучение существующих исследований на тему «Классификация стадий сна»;
2. реализация алгоритмов для предварительной обработки данных и вычисления характеристик сигналов ЭКГ;
3. подготовка набора данных для обучения моделей машинного обучения;
4. реализация моделей машинного обучения;
5. обучение моделей с наилучшими характеристиками;
6. проведение анализа результатов.

Методологические основы исследования в области автоматической классификации стадий сна представлены в работах Qiao Li [2], Niranjan Sridhar [3], Mustafa Radha [4], Redmond J. [5], European Heart Journal [6], Yilmaz B. [7], Telser S. [8], Busek P. [9] и Penzel T. [10].

Практическая значимость бакалаврской работы заключается в исследовании характеристик электрокардиограммы, подходящих для решения задачи, полная подготовка и обработка данных. А также реализация и обучение моделей машинного обучения и нейросетевых алгоритмов с их дальнейшей оптимизацией.

Структура и объём работы. Бакалаврская работа состоит из введения, 3 разделов, заключения, списка использованных источников и 11 приложений. Общий объем работы – 83 страниц, из них 42 страницы – основное содержание, включая 25 рисунков, список использованных источников информации – 26 наименований.

КРАТКОЕ СОДЕРЖАНИЕ РАБОТЫ

Первый раздел «Обзор источников» посвящен существующим исследованиям, рассматривающим методы машинного обучения в задаче классификации стадий сна.

В исследовании «Transfer learning from ECG to PPG for improved sleep staging from wrist-worn wearables» предложен метод трансферного обучения с ЭКГ на фотоплетизмографии (ФПГ) для повышения точности классификации стадий сна с использованием носимых устройств.

В работе «Deep learning for automated sleep staging using instantaneous heart rate» использованы CNN и RNN для анализа мгновенного сердечного ритма, достигнута точность 0,77 при классификации 4 стадий сна.

В исследовании «Sleep stage classification from heart-rate variability using long short-term memory neural networks» применены LSTM-сети для анализа 132 признаков ВСР, показавшие точность до 0,92 для разных стадий сна.

Таким образом, современные методы машинного обучения позволяют эффективно классифицировать стадии сна на основе физиологических сигналов, что способствует развитию доступного мониторинга сна.

Второй раздел «Сон и методы его исследования» посвящен подходам в исследованиях сна, а также изучению методов машинного обучения.

Сон состоит из циклов, включающих медленный (NREM) и быстрый (REM) сон.

- NREM делится на стадии:
 - N1 (засыпание, 1–5 мин),
 - N2 (основная фаза, замедление дыхания, обработка памяти),
 - N3 (глубокий сон, восстановление организма).
- REM (25–30% сна) характеризуется сновидениями, высокой нейронной активностью и играет ключевую роль в обучении и эмоциональной регуляции.

На структуру сна влияют возраст, стресс, заболевания и внешние условия.

В качестве рассматриваемых задач машинного обучения была взята задача многоклассовой классификации. Также были взяты популярные модели, которые используют в рамках этой задачи.

Модели для задачи классификации: метод k ближайших соседей, логистическая регрессия, метод опорных векторов и MLP классификатор, ансамблевые методы, нейросетевые алгоритмы.

Вышеперечисленные модели были выбраны, поскольку все они работают по разным принципам, что позволит легче анализировать полученные результаты, а также выбрать наиболее удобные подходы для решения поставленной задачи.

В качестве метрик для оценки качества в задаче классификации были выбраны: accuracy и f-score, а также матрица ошибок модели. Для лучшей модели был построен полный отчет по метрикам.

Ансамбль алгоритмов (методов) – метод, который использует несколько алгоритмов с целью получения лучшей эффективности, чем при обучении каждого из алгоритмов по отдельности. В работе были рассмотрены алгоритмы градиентного бустинга и случайного леса.

Рекуррентные нейронные сети (RNN) – это особый класс нейронных сетей, разработанный для обработки последовательных данных, где важна временная зависимость между элементами. Их ключевая особенность – наличие обратных связей, позволяющих сохранять информацию о предыдущих состояниях, что делает их особенно полезными для анализа временных рядов и биологических сигналов.

Основные компоненты архитектуры RNN:

- Входной слой
- Скрытое состояние (хранит историю последовательности)
- Выходной слой

Однако классические RNN страдают от проблемы исчезающих/взрывающихся градиентов, что затрудняет обучение на длинных последовательностях.

LSTM-сети (Long Short-Term Memory) были разработаны как усовершенствованная версия RNN для решения этих проблем. Их ключевые особенности:

- Специальные ячейки памяти с тремя типами "ворот":
 1. Входные ворота - регулируют поступление новой информации
 2. Забывающие ворота - контролируют сохранение/удаление старой информации
 3. Выходные ворота - определяют передачу информации на выход

Анализ сна требует комплексного подхода, включающего изучение его фаз, характеристик ВСР и применение ML-методов.

Третий раздел «Реализация автоматического классификатора стадий сна» содержит подробное описание этапов практической части работы.

В качестве среды выполнения использовалась интерактивная облачная среда Google Colaboratory. В практической части использовались следующие библиотеки:

- *Pandas* для работы с табличными данными;
- *Matplotlib* для визуализации данных;
- *Seaborn* для создания статистических графиков;
- *Scipy* для научных исследований;
- *sklearn* для использования моделей машинного обучения и оценки их качества;
- *PyTorch* для использования методов глубокого обучения.

В рамках выполнения практической части были реализованы алгоритмы для расчета следующих характеристик:

1. Временные и статистические параметры

Для классификации стадий сна анализируются RR-интервалы.

- Mean, Median — среднее и медианное значение RR-интервалов.
- SDNN, RMSSD, SDDSD — показатели вариативности сердечного ритма.
- pNN50 — доля интервалов с разницей >50 мс (высокая в REM-сне).
- MAD, PDFA — устойчивые к шумам методы анализа.

2. Спектральные характеристики

Частотный анализ выделяет диапазоны:

- VLF (0.0033–0.04 Гц) — долгосрочная регуляция.
- LF (0.04–0.15 Гц) — симпатическая и парасимпатическая активность.
- HF (0.15–0.4 Гц) — парасимпатическая активность, связанная с дыханием.

LF/HF отражает баланс вегетативной нервной системы:

- Высокое значение — симпатическая активность (REM, бодрствование).
- Низкое — парасимпатическая (глубокий сон).

3. Анализ флуктуаций

- Progressive detrended fluctuation analysis.

В рамках исследования анализировались 44 записи ЭКГ, разметка которых проводилась сомнологами по старой системе классификации стадий сна. Однако новая система появилась на основе старой, поэтому при необходимости, результаты можно адаптировать для новых меток.

Расшифровка кодов в гипнограмме:

- 1,2,3,4 –Стадии сна S1, S2, S3, S4;
- 5 – REM;
- 6 – Бодрствование;
- 0 – Двигательные артефакты(или участки без классификации);
- 9 – Служебные метки.

Кроме того, проводилась предварительная обработка данных – детрендирование. Детрендирование – процесс удаления тренда из сигнала. В дальнейшем характеристики считались как для исходного ряда, так и для детрендированного.

В результате был создан датасет, состоящий из 38 признаков и 36000 строк. Каждый датасет разбивался на тренировочную и тестовую выборки.

Каждая из рассмотренных моделей обучалась по очереди на тренировочных данных, а затем производилось тестирование модели.

Перед началом обучения были заготовлены массивы с гиперпараметрами модели, и обучение производилось на всех комбинациях параметров.

После получения оценок качества обучения всех моделей был проведен сравнительный анализ. Так, были выявлены лучшие одиночные методы ансамблевые методы и нейросетевые алгоритмы для каждой обученной модели машинного обучения.

Точность работы градиентного бустинга составляет 0,62. Точность случайного леса и LightGBM составила 0,65 и 0,68 соответственно. После оптимизации метода LightGBM удалось достигнуть точности 0,71.

Были рассмотрены такие методы, как логистическая регрессия, метод ближайших соседей, метод опорных векторов и библиотечный MLP классификатор.

Точность модели логистической регрессии равна 0,51. Немного лучший результат показал метод опорных векторов, чья точность достигла значения 0,58. Точность MLP Classifier и kNN равна 0,64 и 0,75 соответственно.

При попытке повысить качество метода ближайших соседей путем изменения количества соседей, удалось повысить метрики до значений 0,77.

Были рассмотрены рекуррентные нейронные сети, лучшими из которых стали сети:

- 64 нейрона, 3 слоя, дропаут 0.2, батчсайз 32;
- 256 нейронов, 3 слоя, дропаут 0.2, батчсайз 64.

Точность первой составляет 0,42, а второй 0,52.

В результате выполнения работы удалось достигнуть точности, равной 0,78 для всех предсказаний и 0,83, 0,81 и 0,84 для классов два, четыре и пять, что соответствует следующим стадиям сна S2, S4, REM соответственно.

ЗАКЛЮЧЕНИЕ

В рамках работы были изучены характеристики электрокардиограммы, которые наилучшим образом подходят для задачи автоматической классификации стадий сна. Кроме того, были рассмотрены методы и подходы, а также существующие исследования, которые послужили основой при достижении поставленной цели. В рамках практической части были реализованы алгоритмы для вычисления признаков сигналов ЭКГ и формирования набора данных для обучения моделей машинного обучения. На полученных данных обучались ML-модели, среди которых выбирались наиболее качественные. К таким моделям можно отнести LightGBM, kNN.

В результате выполнения работы удалось достигнуть точности, равной 0,78 для всех предсказаний и 0,83, 0,81 и 0,84 для классов два, четыре и пять, что соответствует следующим стадиям сна S2, S4, REM соответственно. Однако такой точности не удалось достичь у всех меток, поэтому были рассмотрены пути повышения качества моделей, чтобы в дальнейшем приблизиться к более точной классификации стадий сна по сигналам ЭКГ.

Работа была представлена на студенческой научной конференции весной 2025 года.

Отдельные части бакалаврской работы были опубликованы/представлены на конференции:

- Самойчук Н. Б., Лапшева Е. Е. ХАРАКТЕРИСТИКИ ЭЛЕКТРОКАРДИОГРАММЫ ДЛЯ АВТОМАТИЧЕСКОЙ КЛАССИФИКАЦИИ СТАДИЙ СНА // «Студенческая научная конференция факультета компьютерных наук и информационных технологий». СГУ. 2025.

Основные источники информации:

1. Т.В. Карпова Влияние сна на организм человека: статья / Т.В.Карпова – Нижний Новгород – 120с.
2. Qiao Li Transfer learning from ECG to PPG for improved sleep staging from wrist-worn wearables/ Qiao Li, Qichen Li, Ayse S Cakmak, Giulia Da Poian, Donald L Bliwise, Viola Vaccarino, Amit J Shah, Gari D Clifford - Article: 2021 – 15с.
3. Niranjana Sridhar Deep learning for automated sleep staging using instantaneous heart rate/ Niranjana Sridhar, Ali Shoeb, Philip Stephens, Alaa Kharbouch, David Ben Shimol, Joshua Burkart, Atiyeh Ghoreyshi, Lance Myers - Article: 2020 – 15с.
4. Mustafa Radha Sleep stage classification from heart-rate variability using long short-term memory neural networks: scientific report /Mustafa Radha, Pedro Fonseca, Arnaud Moreau, Marco Ross, Andreas Cerny, Peter Anderer, Xi Long, Ronald M.Aarts. - Scientific Reports: 2019 – 11с.
5. Redmond, J. Cardiorespiratory-based sleep staging in subjects with obstructive sleep apnea: article / Redmond, J., Heneghan. - IEEE Transactions on Biomedical Engineering 53: 2006 - 11с.
6. Of the European Society of Cardiology, T. F., the North American Society of Pacing & Electrophysiology. Heart rate variability: Standards of measurement, physiologic interpretation, and clinical use. European Heart Journal 17, 354–81 (1996).

7. Yılmaz, B. Sleep stage and obstructive apneaic epoch classification using single-lead ecg: article / Yılmaz, B., Asyalı, M. H., Arıkan, E., Yetkin, S., Özgen, F. - Biomedical engineering online:2010 – 20c.
8. Telser, S. Can one detect sleep stage transitions for on-line sleep scoring by monitoring the heart rate variability: report / Telser, S. – Somnologie:2004 – 45c.
9. Bušek, P. Spectral analysis of the heart rate variability in sleep: article / Bušek, P., Vaňková, J., Opavský, J., Salinger, J. - Physiological Research: 2005 - 369c.
10. Penzel, T., Comparison of detrended fluctuation analysis and spectral analysis for heart rate variability in sleep and sleep apnea: report / Penzel, T., Kantelhardt, J. W., Grote, L., Peter, J.-H. H. & Bunde, A. - IEEE Transactions on Biomedical Engineering:2003 – 10c.