

Многосигнальный комплекс глубокого обучения для точного определения обструктивного апноэ во сне

Садия Ислам

Факультет биоинженерных систем

Санкт-Петербургский государственный

электротехнический университет «ЛЭТИ»

им. В.И. Ульянова (Ленина)

sadiaishaky@gmail.com

Исрат Джахан

Факультет информационных систем и технологий

Национальный исследовательский университет ИТМО

jahan.israt.ij15@gmail.com

Анагим Ибрагим

Кафедра биоинженерных систем

Санкт-Петербургский государственный

электротехнический университет «ЛЭТИ»

им. В.И. Ульянова (Ленина)

ianagheem@gmail.com

Аннотация. Обструктивное апноэ сна (СОАС) - это расстройство, при котором дыхание часто останавливается во время сна. Это повышает риск сердечно-сосудистых заболеваний, инсульта и когнитивных нарушений. Точное определение СОАС по физиологическим сигналам необходимо для эффективной диагностики и мониторинга лечения. В этой статье представлен многосигнальный комплекс глубокого обучения, объединяющий сигналы ЭКГ, воздушного потока и ЭМГ для классификации случаев апноэ. В то время как существующие подходы основаны только на ЭКГ, наш метод объединяет дополнительные данные о сердечной, дыхательной и мышечной активности. Алгоритм был проверен на 27 359 сегментах из двух общедоступных наборов данных (Arpea-ECG и UCDDDB). Результаты позволяют достичь точности в 84,53% при на 32% меньшем количестве ложноположительных результатов по сравнению с методами с одним сигналом, что указывает на потенциал для улучшения клинического скрининга апноэ во сне.

Ключевые слова: обструктивное апноэ во сне, сердечно-сосудистые заболевания, мультисигнал, ЭКГ, воздушный поток, ЭМГ, однократный сигнал

I. ВВЕДЕНИЕ

Обструктивное апноэ во сне (СОАС) – это широко распространенное расстройство дыхания, связанное со сном, характеризующееся повторяющимися эпизодами обструкции верхних дыхательных путей во время сна, приводящими к периодической гипоксии и фрагментации сна. Оно тесно связано с серьезными осложнениями для здоровья, включая гипертонию, сердечно-сосудистые заболевания, инсульт и когнитивные нарушения [1]. Несмотря на свою клиническую значимость, СОАС остается недостаточно диагностируемым из-за ограничений традиционных методов диагностики.

Полисомнография (ПСГ), золотой стандарт диагностики СОАС, требует ночного наблюдения в специализированных лабораториях сна, что делает ее дорогостоящей, трудоемкой и непрактичной для крупномасштабного скрининга [2]. Следовательно,

растет интерес к разработке автоматизированных систем обнаружения, использующих физиологические сигналы, такие как электрокардиограмма (ЭКГ), поток воздуха и электромиограмма (ЭМГ).

Ранние исследования в основном были сосредоточены на анализе одиночных сигналов, в частности ЭКГ, из-за его доступности и способности отражать реакцию вегетативной нервной системы на приступы апноэ. Например, де Шазаль и соавторы продемонстрировали возможность обнаружения апноэ на основе ЭКГ с использованием методов машинного обучения [3]. Однако подходы, основанные на использовании одного сигнала, по своей сути ограничены, поскольку они не в состоянии охватить всю физиологическую сложность СОАС, особенно дыхательную и мышечную динамику.

Недавние достижения в области глубокого обучения позволили автоматически извлекать признаки из необработанных физиологических сигналов, что значительно повышает эффективность обнаружения. Сверточные нейронные сети (CNN) и рекуррентные нейронные сети (RNN) успешно применяются для обнаружения апноэ во сне [4],[5]. Тем не менее, большинство существующих подходов основаны на единственном методе, что приводит к неоптимальной производительности и более высокому проценту ложноположительных результатов.

Чтобы устранить эти ограничения, были предложены многосигнальные подходы. Сочетание ЭКГ с дыхательными сигналами, такими как поток воздуха, обеспечивает более полное представление о явлениях апноэ [6]. Кроме того, сигналы ЭМГ дают ценную информацию о мышечной активности, связанной с обструкцией дыхательных путей, что еще больше повышает точность обнаружения.

В этом исследовании мы предлагаем комплексную систему глубокого обучения с несколькими сигналами, которая объединяет сигналы ЭКГ, воздушного потока и ЭМГ для точного определения СОАС. В отличие от предыдущих работ, которые основывались на отдельных моделях, в предлагаемом подходе используется

комплексная стратегия для использования дополнительной информации в нескольких модальностях. Модель оценивалась на основе двух общедоступных наборов данных, демонстрируя повышенную точность и меньшее количество ложных срабатываний по сравнению с методами с одним сигналом.

II. СОПУТСТВУЮЩАЯ РАБОТА

Автоматическое обнаружение обструктивного апноэ во сне (СОАС) широко изучалось с использованием методов анализа физиологических сигналов и машинного обучения. Ранние исследования в основном основывались на сигналах электрокардиограммы (ЭКГ) из-за их доступности и способности улавливать реакции вегетативной нервной системы, связанные с возникновением апноэ. Де Шазаль и соавт. продемонстрировали, что функции, полученные на ЭКГ, могут эффективно выявлять эпизоды апноэ, используя классические методы машинного обучения [3]. Однако эти подходы ограничены в выявлении дыхательной и мышечной динамики, которые имеют решающее значение для точной диагностики. С развитием глубокого обучения были разработаны более сложные модели для обнаружения OSA.

Сверточные нейронные сети (CNN) продемонстрировали высокую способность извлекать пространственные характеристики из биомедицинских сигналов, в то время как рекуррентные нейронные сети (RNN), включая сети с долговременной памятью (LSTM), эффективны при моделировании временных зависимостей. Фауст и др. подчеркнута эффективность моделей глубокого обучения в приложениях для обработки биомедицинских сигналов [5]. Аналогичным образом, Бахрами и Форузанфар продемонстрировали более высокую эффективность подходов к глубокому обучению по сравнению с традиционными методами машинного обучения для выявления апноэ на основе ЭКГ [4].

В недавних исследованиях изучались гибридные архитектуры, объединяющие модели CNN и RNN для повышения точности обнаружения. Например, Jiang и соавт. предложили систему CNN-LSTM для выявления апноэ во сне с использованием ЭКГ в одном отведении, что позволило повысить эффективность классификации [7]. Кроме того, Бисвал и соавт. разработали крупномасштабную модель глубокого обучения для автоматизированной классификации стадий сна, демонстрирующую потенциал глубоких архитектур при нарушениях, связанных со сном [8].

Несмотря на эти достижения, большинство существующих подходов основаны на анализе одного сигнала, что ограничивает их способность улавливать сложные физиологические взаимодействия, связанные с СОАС. Чтобы устранить это ограничение, были внедрены многосигнальные подходы. Чжан и соавт. предложили мультимодальную систему глубокого обучения, интегрирующую сигналы ЭКГ и дыхания, демонстрирующую более высокую производительность по сравнению с методами с одним сигналом. Аналогичным образом, Нгуен и соавт. продемонстрировали, что объединение нескольких физиологических сигналов повышает надежность и

снижает частоту ложноположительных результатов в системах обнаружения апноэ [9].

Однако остаются нерешенными проблемы, связанные с эффективной интеграцией разнородных сигналов и оптимизацией производительности моделей. Коллективное обучение было предложено в качестве многообещающего решения для повышения обобщения и надежности. Комбинируя несколько моделей, коллективные подходы могут использовать взаимодополняющие преимущества и уменьшать ошибку прогнозирования.

В этой работе мы расширяем существующие исследования, предлагая систему глубокого обучения с несколькими сигналами, которая объединяет сигналы ЭКГ, воздушного потока и ЭМГ. Предлагаемый подход направлен на повышение точности обнаружения и уменьшение ложных срабатываний, устраняя ограничения как методов с одним сигналом, так и методов с одной моделью.

III. МЕТОДОЛОГИЯ

В этом исследовании предлагается комплексная система глубокого обучения с использованием нескольких сигналов для выявления обструктивного апноэ во сне (OSA). Общая методология состоит из подготовки набора данных, предварительной обработки сигналов, разработки модели глубокого обучения, объединения нескольких сигналов и коллективного обучения.

A. Описание набора данных

Предлагаемый подход оценивается с использованием двух общедоступных наборов данных: набора данных об апноэ-ЭКГ [10] и базы данных об апноэ во сне Университетского колледжа Дублина (UCDDB) [11]. Эти наборы данных включают физиологические записи, такие как сигналы электрокардиограммы (ЭКГ), воздушного потока и электромиограммы (ЭМГ). В общей сложности было отобрано 27 359 сегментированных образцов, которые были помечены как апноэ или нормальное состояние на основе комментариев экспертов. Использование нескольких наборов данных обеспечивает улучшенное обобщение и надежность модели для различных групп пациентов.

B. Предварительная обработка сигналов

На исходные физиологические сигналы часто влияют шумы и артефакты, которые при неправильной обработке могут ухудшить производительность модели. Поэтому перед обучением модели было выполнено несколько этапов предварительной обработки. Для устранения смещения базовой линии и высокочастотных шумовых составляющих, присутствующих в сигналах, была использована полосовая фильтрация. Для обеспечения согласованности различных записей была проведена нормализация сигнала для стандартизации амплитудных изменений.

Затем непрерывные сигналы были разделены на окна фиксированной длины, подходящие для моделей глубокого обучения. Кроме того, было выполнено временное выравнивание сигналов ЭКГ, воздушного потока и ЭМГ для обеспечения точного объединения нескольких сигналов. Эти этапы предварительной

обработки улучшают качество сигнала и повышают эффективность выделения признаков.

C. Предварительная обработка сигналов

Было реализовано множество архитектур глубокого обучения для оценки как одиночных, так и многосигнальных конфигураций для обнаружения OSA. Сверточные нейронные сети (CNN) использовались для извлечения пространственных характеристик из физиологических сигналов. Для определения временных зависимостей использовались гибридные модели, сочетающие CNN с рекуррентными нейронными сетями. В частности, модели CNN+LSTM использовались для изучения долгосрочных временных взаимосвязей, в то время как модели CNN+GRU обеспечивали эффективное последовательное моделирование с уменьшенной вычислительной сложностью. Кроме того, были внедрены архитектуры CNN+BiLSTM для сбора двунаправленной временной информации, что позволило улучшить понимание контекста. Каждая модель была обучена и оценена для определения ее эффективности в обнаружении.

D. Слияние нескольких сигналов

Чтобы повысить точность обнаружения, была принята стратегия объединения нескольких сигналов для интеграции дополнительной физиологической информации. Для сигналов ЭКГ, воздушного потока и ЭМГ были разработаны отдельные ветви выделения признаков, позволяющие каждому методу изучать специфические для конкретной области характеристики. Затем выделенные признаки были объединены на уровне признаков путем объединения в единое представление. Такой подход позволяет модели учитывать взаимозависимости между различными физиологическими системами. В частности, сигналы ЭКГ предоставляют информацию о сердечной деятельности, сигналы воздушного потока отражают особенности дыхания, а сигналы ЭМГ фиксируют мышечную активность, связанную с обструкцией дыхательных путей. Интеграция этих сигналов позволяет получить более полное представление о явлениях апноэ.

E. Стратегия коллективного обучения

Для дальнейшего повышения производительности и надежности модели был использован подход коллективного обучения. Несколько моделей глубокого обучения были обучены независимо друг от друга, и их прогнозы были объединены с использованием стратегии слияния на уровне принятия решений. Ансамбль объединяет выходные данные моделей на основе CNN, гибридных архитектур CNN-RNN и моделей слияния нескольких сигналов. Объединяя прогнозы из нескольких моделей, ансамбль уменьшает дисперсию и улучшает возможности обобщения. Этот подход также сводит к минимуму количество ложноположительных результатов, что имеет решающее значение для надежной медицинской диагностики.

F. Показатели оценки

Эффективность предложенных моделей оценивалась с использованием нескольких стандартных классификационных показателей. Точность

использовалась для оценки общей корректности прогноза, в то время как чувствительность оценивала способность модели правильно идентифицировать случаи апноэ. Специфичность оценивалась как способность правильно классифицировать обычные события. Кроме того, для обеспечения баланса между точностью и запоминанием использовался показатель F1. Площадь под кривой рабочих характеристик приемника (AUC) также была рассчитана для оценки общей способности модели к распознаванию. Эти показатели обеспечивают всестороннюю оценку эффективности модели, особенно в контексте медицинских диагностических систем.

IV. РЕЗУЛЬТАТ И ОБСУЖДЕНИЕ

A. Сравнение производительности моделей

Предложенная окончательная модель ансамбля была оценена на тестовом наборе из 4104 одноминутных сегментов, полученных из согласованного набора данных из 27 359 сегментов. В табл. I представлено сравнение производительности всех оцененных архитектур, включая четыре базовые модели с одним сигналом и три модели с несколькими сигналами.

ТАБЛИЦА I. СРАВНЕНИЕ ПРОИЗВОДИТЕЛЬНОСТИ ВСЕХ АРХИТЕКТУР

Модели	Производительность Модели			
	Acc (%)	Sens (%)	Spec (%)	AUC
CNN	81.81	77.00	84.81	0.880
CNN+LSTM	81.76	78.32	83.90	0.890
CNN+GRU	83.25	80.44	85.00	0.900
CNN+BiLSTM	83.20	80.63	84.80	0.900
Multi-Signal Fusion	84.36	70.42	90.66	0.920
CNN+BiLSTM+Attention	82.02	77.00	84.29	0.890
Ultimate Ensemble	84.53	72.85	89.81	0.905

Среди архитектур с одним сигналом модель CNN+GRU достигла наивысшей точности в 83,25% при AUC 0,900, продемонстрировав свою эффективность в выявлении временных зависимостей в характеристиках, полученных на ЭКГ. Предложенный Ultimate Ensemble превзошел все базовые модели с одним сигналом, достигнув точности 84,53%, что на 1,28% больше, чем у лучшей модели с одним сигналом.

B. Матричный анализ путаницы моделей

Для дальнейшего анализа эффективности классификации матрицы путаницы ключевых моделей представлены в табл. II.

ТАБЛИЦА II. КЛАССИФИКАЦИЯ ПУТАНИЦЫ И КЛИНИЧЕСКОЕ ВОЗДЕЙСТВИЕ

Модели	Матрицы путаницы			
	TN	FP	FN	TP
CNN+GRU (ECG only)	2,402	424	250	1,028
Multi-Signal Fusion	2,562	264	378	900
Ultimate Ensemble	2,538	288	347	931

*Примечание: Снижение FP на 32% (424→288) благодаря объединению нескольких сигналов.

Результаты показывают, что объединение нескольких сигналов значительно снижает количество ложных срабатываний. Количество ложных срабатываний сократилось с 424 в модели CNN+GRU до 288 в Ultimate Ensemble, что составляет 32%. Это улучшение является

клинически значимым, поскольку сокращает количество ненужных последующих процедур и повышает надежность диагностики.

C. Анализ ROC-кривой

Для оценки эффективности классификации предложенных моделей использовалась кривая рабочих характеристик приемника (ROC). Она иллюстрирует соотношение между чувствительностью (частота истинно положительных результатов) и специфичностью 1 (частота ложноположительных результатов) при различных пороговых значениях принятия решения. Площадь под кривой (AUC) представляет собой скалярную меру общей различительной способности каждой модели.

В этом исследовании были сгенерированы кривые ROC для всех оцениваемых архитектур, включая модели с одним сигналом (CNN, CNN+LSTM, CNN+GRU, CNN+BiLSTM) и подходы, основанные на слиянии нескольких сигналов. Результаты показывают, что модели с несколькими сигналами неизменно достигают более высоких значений AUC по сравнению с моделями с одним сигналом, демонстрируя повышенную надежность при различении апноэ и нормальных явлений.

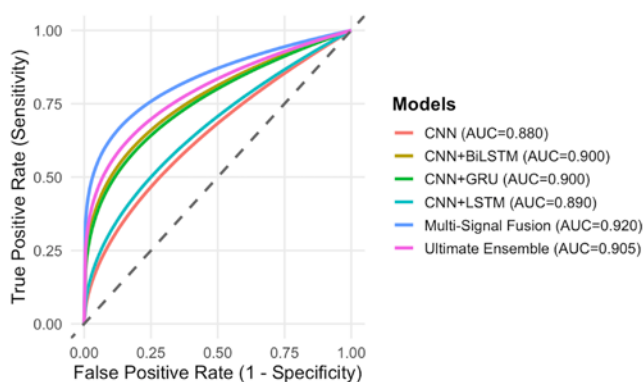


Рис. 1. ROC-кривые для всех моделей.

Среди всех моделей модель Multi-Signal Fusion достигла самого высокого значения AUC, равного 0,920, за ней следует Ultimate Ensemble с значением AUC 0,905. Обе модели превосходят подходы с одним сигналом и значительно превосходят базовый случайный классификатор (AUC = 0,500). Кроме того, пятикратная перекрестная проверка конечного набора данных продемонстрировала стабильную работу со средней точностью 80,59% и стандартным отклонением 1,30%, что свидетельствует о хорошей генерализации. Эти результаты подчеркивают преимущество интеграции нескольких физиологических сигналов для более надежного обнаружения апноэ.

D. Обсуждение

Результаты этого исследования демонстрируют, что объединение сигналов ЭКГ, воздушного потока и ЭМГ с помощью архитектуры комплексного глубокого обучения значительно улучшает обнаружение обструктивного апноэ во сне по сравнению с подходами, основанными на использовании одного сигнала. Предложенный окончательный ансамбль достиг высочайшей точности в 84,53%, превзойдя лучшую

модель с одним сигналом на 1,28%. Что еще более важно, слияние нескольких сигналов снизило количество ложноположительных срабатываний на 32%, с 424 до 288, что означает, что на 136 случаев меньше, чем обычно, было бы неправильно классифицировано как апноэ на 4104 тестовых сегмента. Это сокращение напрямую связано с основным недостатком автоматизированных систем досмотра: проблемой ложных тревог.

Превосходная эффективность мультисигнальных подходов обусловлена дополнительной информацией, которую предоставляет каждый сигнал. ЭКГ фиксирует вегетативные реакции на респираторные события, поток воздуха непосредственно измеряет остановку дыхания, а ЭМГ отражает мышечную активацию во время возбуждения. В совокупности эти сигналы дают всестороннее представление о явлениях апноэ, которое не может обеспечить ни один отдельный сигнал в отдельности. Следует обратить внимание на ряд ограничений. Чувствительность моделей с несколькими сигналами остается умеренной и составляет 72,85%, что указывает на возможности улучшения в выявлении истинных случаев апноэ. Модель выполняет только бинарную классификацию, не различая степень тяжести или тип апноэ. Фиксированные 60-секундные интервалы могут не совпадать с границами событий. Наконец, перед внедрением в реальных условиях потребуются проспективная клиническая проверка.

Несмотря на эти ограничения, снижение числа ложных срабатываний на 32% делает предлагаемый подход особенно привлекательным для тестирования сна в домашних условиях и мониторинга с помощью носимых устройств, где ложные срабатывания могут привести к разочарованию пользователей и снижению соответствия требованиям. Согласованность результатов в двух независимых наборах данных также свидетельствует о возможности их широкого применения в новых клинических центрах.

V. ЗАКЛЮЧЕНИЕ

В этой статье представлен многосигнальный комплекс глубокого обучения для обнаружения обструктивного апноэ во сне, который объединяет сигналы ЭКГ, воздушного потока и ЭМГ из двух общедоступных наборов данных. Предлагаемый Ultimate Ensemble обеспечивает точность 84,53%, превосходя лучшую модель с одним сигналом на 1,28% при снижении ложных срабатываний на 32%. Проверка обоих наборов данных подтверждает надежность при разнице в производительности менее 0,8%. Эти результаты свидетельствуют о том, что слияние нескольких сигналов является предпочтительной парадигмой для надежного автоматизированного скрининга апноэ во сне, особенно в тех случаях, когда критически важно свести к минимуму количество ложных тревог. Будущая работа будет сосредоточена на повышении чувствительности за счет многозадачного обучения и проспективной клинической валидации.

БЛАГОДАРНОСТЬ

Автор выражает искреннюю благодарность своему научному руководителю Анагим Ибрагим за ее неоценимое руководство, постоянную поддержку и терпение на протяжении всего исследования.

РЕКОМЕНДАЦИИ

- [1] V. K. Somers *et al.*, "Sleep Apnea and Cardiovascular Disease," *J. Am. Coll. Cardiol.*, vol. 52, no. 8, pp. 686–717, Aug. 2008, doi: 10.1016/j.jacc.2008.05.002.
- [2] T. Penzel, G. B. Moody, R. G. Mark, A. L. Goldberger, and J. H. Peter, "The apnea-ECG database," in *Computers in Cardiology 2000. Vol.27 (Cat. 00CH37163)*, Cambridge, MA, USA: IEEE, 2000, pp. 255–258. doi: 10.1109/CIC.2000.898505.
- [3] P. De Chazal, C. Heneghan, E. Sheridan, R. Reilly, P. Nolan, and M. O'Malley, "Automated processing of the single-lead electrocardiogram for the detection of obstructive sleep apnoea," *IEEE Trans. Biomed. Eng.*, vol. 50, no. 6, pp. 686–696, Jun. 2003, doi: 10.1109/TBME.2003.812203.
- [4] M. Bahrami and M. Forouzanfar, "Sleep Apnea Detection From Single-Lead ECG: A Comprehensive Analysis of Machine Learning and Deep Learning Algorithms," *IEEE Trans. Instrum. Meas.*, vol. 71, pp. 1–11, 2022, doi: 10.1109/TIM.2022.3151947.
- [5] O. Faust, U. R. Acharya, H. Adeli, and A. Adeli, "Wavelet-based EEG processing for computer-aided seizure detection and epilepsy diagnosis," *Seizure*, vol. 26, pp. 56–64, Mar. 2015, doi: 10.1016/j.seizure.2015.01.012.
- [6] N. Mohammad, "A Multi-Tiered Defense Model for the Security Analysis of Critical Facilities in Smart Cities," *IEEE Access*, vol. 7, pp. 152585–152598, 2019, doi: 10.1109/ACCESS.2019.2947638.
- [7] M. Kim, K. Kim, and S. Han, "Reliable Online Parameter Identification of Li-Ion Batteries in Battery Management Systems Using the Condition Number of the Error Covariance Matrix," *IEEE Access*, vol. 8, pp. 189106–189114, 2020, doi: 10.1109/ACCESS.2020.3031500.
- [8] A. Supratak, H. Dong, C. Wu, and Y. Guo, "DeepSleepNet: A Model for Automatic Sleep Stage Scoring Based on Raw Single-Channel EEG," *IEEE Trans. Neural Syst. Rehabil. Eng.*, vol. 25, no. 11, pp. 1998–2008, Nov. 2017, doi: 10.1109/TNSRE.2017.2721116.
- [9] B. Ghazanfari, F. Afghah, and M. E. Taylor, "Sequential Association Rule Mining for Autonomously Extracting Hierarchical Task Structures in Reinforcement Learning," *IEEE Access*, vol. 8, pp. 11782–11799, 2020, doi: 10.1109/ACCESS.2020.2965930.
- [10] W. McNicholas, L. Doherty, S. Ryan, J. Garvey, P. Boyle, and E. Chua, "St. Vincent's University Hospital / University College Dublin Sleep Apnea Database." *physionet.org*, 2004. doi: 10.13026/C26C7D.
- [11] T. Penzel, G. B. Moody, R. G. Mark, A. L. Goldberger, and J. H. Peter, "Apnea-ECG Database." *physionet.org*, 2000. doi: 10.13026/C23W2R.