

# Гибридный подход к обнаружению нарушений сна на основе графовых нейронных сетей

Мохамед Ахмед Абд Мовафи

*Санкт-Петербургский государственный  
электротехнический университет  
«ЛЭТИ» им. В.И. Ульянова (Ленина)*

mowafy7@gmail.com

Евгения С. Новикова

*Санкт-Петербургский государственный  
электротехнический университет  
«ЛЭТИ» им. В.И. Ульянова (Ленина)*

esnovikova@etu.ru

**Аннотация.** Неинвазивный мониторинг окружающей среды с использованием датчиков представляет собой альтернативу лабораторным методам оценки качества сна, однако выявление значимых возмущений по многомерным сигналам окружающей среды представляет собой сложную задачу. В работе представлен гибридный подход выявления нарушения сна на основе анализа данных от окружающей среды. Предложенный подход представляет собой комбинацию робастного статистического оценивания на основе скользящей медианы и медианного абсолютного отклонения, распространение оценок отклонений с учетом взвешенного графа зависимостей между датчиками и результаты пространственно-временного прогнозирования с использованием графовой нейронной сети. Выполнены эксперименты с использованием данных от «умной» комнаты, которые включают параметры освещенности, температуры, шума и движения в окружающей среде. В результате было показано, что статистический компонент более чувствителен к резким локальным отклонениям, тогда как нейросетевой компонент выявляет более устойчивые временные изменения в окружающей среде. Предложенный подход формирует интерпретируемую основу для долгосрочного мониторинга среды сна на основе датчиков среды.

**Ключевые слова:** мониторинг сна, обнаружение аномалий, графовые нейронные сети, интеллектуальные среды, многомерные временные ряды

## I. ВВЕДЕНИЕ

Сон играет важнейшую роль в поддержании когнитивной работоспособности, физического здоровья и общего благополучия. Низкое качество сна связано с различными нарушениями здоровья, включая снижение концентрации внимания, повышение уровня стресса и долгосрочные физиологические расстройства. По этой причине мониторинг условий сна и выявление потенциальных возмущений стали важной исследовательской задачей в здравоохранении и системах интеллектуальных сред.

Полисомнография широко рассматривается как клинический стандарт диагностики нарушений сна. Однако она требует специализированного оборудования, контролируемых лабораторных условий и экспертного наблюдения, что делает ее малоприменимой для долгосрочного мониторинга в повседневных условиях. В связи с этим исследователи все активнее обращаются к альтернативным подходам, основанным на технологиях

Интернета вещей, обеспечивающих неинвазивный мониторинг состояний, связанных со сном.

Датчики мониторинга окружающей среды, такие как датчики шума, освещенности, температуры и движения позволяют сформировать полезную информацию об условиях окружающей среды, формирующую контекст для анализа состояния сна. Однако выявление семантически значимых отклонений в таких данных представляет собой сложную задачу, поскольку они обычно проявляются как согласованные изменения нескольких переменных, а не как изолированные аномалии в одном сигнале.

Традиционные методы мониторинга, основанные на правилах, привлекательны благодаря своей простоте и интерпретируемости, однако они часто анализируют каждую переменную независимо и поэтому могут упускать связи между различными факторами среды. Модели глубокого обучения способны выявлять сложные временные паттерны в многомерных временных рядах, хотя их решения зачастую трудно интерпретировать. В данной работе предлагается комбинировать данные методы, предлагаемый подход сочетает робастное статистическое оценивание на основе скользящей медианы и медианного абсолютного отклонения, распространение оценок отклонений с учетом взвешенного графа зависимостей между датчиками и результаты пространственно-временного прогнозирования с использованием графовой нейронной сети для моделирования временной динамики данных от датчиков.

Основной вклад работы заключается в следующем:

- 1) задача мониторинга нарушений сна формулируется как задача обнаружения аномалий в многомерных данных датчиков, представленных в виде графа связанных датчиков;
- 2) предложен гибридный подход к обнаружению нарушений сна, объединяющий статистические правила, и пространственно-временное нейросетевое оценивание отклонения данных;
- 3) выполнена оценка на данных среды умной комнаты для анализа поведения каждого из предложенных компонент для решения предложенной задачи.

ТАБЛИЦА I.

Метод	Основная идея	Связи между датчиками	Интерпретируемость	Ограничение
Статистическое обнаружение аномалий [3]	Выявляет отклонения по статистическим порогам	Нет	Высокая	Не учитывает многомерные зависимости
Мониторинг на основе датчиков среды [4], [5]	Использует датчики среды для анализа сна	Ограниченно	Средняя	Ограниченные возможности обнаружения аномалий
Обнаружение аномалий на основе LSTM	Изучает временные паттерны с помощью рекуррентных сетей	Ограниченно	Низкая	Трудна для интерпретации
MTAD-GAT [6]	Графовые сети внимания для многомерных аномалий	Да	Средняя	Высокая сложность модели
Graph Deviation Network (GDN) [7]	Обучает структуру графа датчиков	Да	Средняя	Требует большого объема обучающих данных
StackVAE-G [8]	Вариационный автокодировщик с обучением графа	Да	Средняя	Вычислительные затраты
Предлагаемая схема	Статистические правила + распространение по графу + ST-GNN	Да	Высокая	Требует калибровки порогов

## II. ОБЗОР ЛИТЕРАТУРЫ

Датчики среды все чаще рассматриваются как инструмент неинвазивного мониторинга качества сна. В отличие от традиционных методов оценки сна, таких как полисомнография, требующих специализированного оборудования и контролируемых лабораторных условий, системы умного дома обеспечивают непрерывное наблюдение за параметрами среды в повседневных жилых пространствах. Предыдущие исследования показали, что датчики среды и активности могут предоставлять полезную контекстную информацию, связанную с характеристиками сна. Так, Дж. Лиу и др. продемонстрировали, что сигналы среды в умных домах могут использоваться для мониторинга состояний, связанных со сном [1], а П. Давали и др. показали, что данные об активности, получаемые от умного дома, дают возможность оценить когнитивное состояние и состояние здоровья на основе данных активности [2].

Статистические методы обнаружения аномалий по-прежнему широко используются в системах мониторинга благодаря своей простоте и интерпретируемости. Систематический анализ методов обнаружения аномалий, подчеркнувший важность статистических подходов для выявления необычных паттернов во временных рядах, представлен в [3]. В сенсорных средах робастные статистические методы, такие как медианная нормализация и медианное абсолютное отклонение (MAD), особенно полезны, поскольку они наименее чувствительны к шуму и экстремальным выбросам, чем традиционные меры, основанные на среднем значении.

С ростом числа приложений машинного обучения, модели глубокого обучения также получили широкое распространение в задаче обнаружения аномалий в многомерных временных рядах. Рекуррентные нейронные сети обычно используются для учета временных зависимостей в последовательных данных. Во многих подходах к обнаружению аномалий, основанных на прогнозировании, модели изучают нормальное поведение системы и фиксируют аномалии, когда ошибка прогноза превышает заранее заданный порог. В последнее время для учета пространственных взаимосвязей между параметрами многомерного временного ряда применяются графовые нейронные сети (GNN) для обнаружения аномалий в многомерных временных рядах. Графовые модели представляют

датчики как вершины графа и описывают отношения между ними с помощью ребер [4]. Эта идея была распространена на динамические среды в виде пространственно-временных графовых сверточных сетей, объединяющих графовую свертку с временным моделированием [5]. Например, в [6] предложена модель MTAD-GAT, в которой реализован механизм внимания, для повышения точности решения задач прогнозирования и реконструкции. Другим значимым методом является модель отклонения графа (Graph Deviation Network, GDN), предложенная в [7], которая обучает отношения между датчиками и выявляет аномалии как отклонения от предсказанного графового поведения [7]. Гибридные подходы, такие как StackVAE-G, дополнительно сочетают обучение графа с вариационными автокодировщиками для учета как структурных взаимосвязей, так и временных паттернов в многомерных сенсорных данных [8].

Несмотря на высокую результативность современных графовых нейронных сетей, многие подходы остаются вычислительно сложными и трудными для интерпретации. В условиях ограниченных вычислительных ресурсов устройств Интернета Вещей возникает необходимость построения адаптивных вычислительно легких моделей. Предлагаемая в данной работе схема решает обозначенную проблему, объединяя робастное статистическое оценивание и пространственно-временное нейросетевое прогнозирование в гибридной архитектуре.

## III. ПРЕДЛАГАЕМАЯ МЕТОДИКА

Предлагаемый подход состоит из двух компонент. Первая компонент использует робастную статистику и распространение оценки по взвешенному графу связей между сенсорами для выявления резких согласованных отклонений параметров среды. Второй компонент использует графовую нейронную сеть для моделирования временной динамики и выявления аномалий по ошибке прогноза.

В каждый момент времени  $t$  среда представляется четырехмерным вектором  $x_t$ , состоящим из измерений шума, освещенности, температуры и движения. Цель состоит в выявлении тех моментов времени, в которых многомерное состояние среды достаточно отклоняется от типичного ночного поведения и тем самым указывает на возможное нарушение сна.

#### A. Робастное статистическое оценивание

Для каждого датчика компонент вычисляет оценки отклонения в скользящих окнах с использованием скользящих медиан и скользящего медианного абсолютного отклонения (MAD). Такое решение снижает чувствительность к асимметричным распределениям и кратковременным всплескам, которые иначе доминировали бы в статистиках, основанных на среднем. Затем применяются контекстные временные правила, чтобы детектор фокусировался на правдоподобных временных интервалах возмущений, связанных со сном.

$$z_i(t) = (x_i(t) - m_i(t)) / (1.4826 \cdot MAD_i(t)) \quad (1)$$

$$s(t) = \frac{1}{4} \sum_{i=1}^4 |z_i(t)| \quad (2)$$

Взаимодействия между датчиками моделируются с помощью взвешенного графа, в котором ребра кодируют ожидаемые зависимости между параметрами среды. В текущей реализации сильные связи задаются между шумом и движением, умеренные — между освещенностью и движением, а более слабые — между температурой и движением. Распространение по графу усиливает свидетельства аномалии, когда несколько связанных датчиков одновременно отклоняются от нормы, тем самым повышая чувствительность к согласованным событиям, которые были бы менее заметны при независимых правилах для каждого датчика.

$$sboost(t) = s(t) + \alpha \cdot \max(0, A \cdot s(t)), \alpha = 0.5 \quad (3)$$

Усиленная оценка используется как основной индикатор аномалии в ветви на основе правил. В текущих экспериментах аномальные флаги для этой ветви формируются, когда усиленная оценка превышает калиброванный порог  $\tau_{rule} = 1.0$ , тогда как нормализованные версии оценки используются для визуализации.

#### B. Пространственно-временное нейросетевое прогнозирование

На вход графовой нейронной сети ST-GNN подаются скользящие окна многомерных временных рядов, к которым последовательно применяется графовая свертка, блок GRU для моделирования временных зависимостей. Сеть прогнозирует следующее состояние, а аномалии оцениваются по ошибке прогноза. Эта ветвь предназначена для выявления отклонений, сохраняющихся достаточно долго, чтобы нарушить усвоенную временную динамику среды.

$$e(t) = \frac{1}{4} \sum_{i=1}^4 |\hat{x}_{t+1}^{(i)} - x_{t+1}^{(i)}| \quad (4)$$

$$A_{gnn}(t) = \mathbf{1}[e(t) > \tau_{gnn}], \tau_{gnn} = 1.0 \quad (5)$$

В настоящем исследовании используется параллельная гибридная схема. Индикаторы ветви на основе правил и ST-GNN вычисляются независимо, а затем анализируются совместно для понимания их комплементарного поведения. В практической системе момент времени может быть помечен для приоритетной проверки при срабатывании любой из ветвей, тогда как в будущих работах может быть предложена калиброванная стратегия позднего слияния,

объединяющая обе оценки в единое правило принятия решения.

## IV. ЭКСПЕРИМЕНТЫ И РЕЗУЛЬТАТЫ

### A. Набор данных и предварительная обработка

Эксперименты проводились с использованием набора данных интеллектуальной среды, содержащего измерения параметров среды, собранные в жилом помещении типа smart-room. Набор включает четыре типа сенсорных сигналов, релевантных для условий среды, связанных со сном: уровень шума, освещенность, температуру и двигательную активность. Запись данных охватывает примерно двадцать дней мониторинга и содержит 10,129 наблюдений с нерегулярными интервалами дискретизации. Медианный интервал времени между последовательными наблюдениями составляет около 31 секунды, что отражает асинхронный характер передачи данных, типичный для многих сенсорных систем интеллектуальной среды. Данные были записаны в нерегулярные моменты времени, для получения согласованного временного представления, пригодного как для статистического анализа, так и для нейросетевого моделирования, потребовалась предварительная обработка. Для этого данные были дискретизированы с равномерным временным шагом в одну минуту. Возникшие пропущенные значения были обработаны с помощью линейной интерполяции. После предварительной обработки набор данных увеличился до 28,692 наблюдений, которые использовались в качестве входных данных в экспериментах по обнаружению аномалий.

ТАБЛИЦА II.

Метрика	Исходные данные	После предобработки
Общее число наблюдений	10,129	28,692
Длительность мониторинга	~20 дней	~20 дней
Медианный интервал	31 с	1 минута
Пропущенные значения	Нерегулярная дискретизация	0 после интерполяции

Важно отметить, что, в отличие от многих эталонных наборов данных для обнаружения аномалий, данный набор не содержит размеченных событий, нарушающих сон, или истинных аннотаций аномалий. Поэтому оценивание в настоящей работе сосредоточено на исследовательском анализе оценок аномальности и обнаруженных событий, а не на контролируемых метриках качества, таких как precision, recall или F1-score. Таким образом, основная цель экспериментов состоит в изучении того, как предложенная гибридная схема реагирует на потенциальные возмущения среды, а также в анализе поведения компонент обнаружения на основе правил и нейронных сетей.

В табл. II представлены ключевые характеристики набора данных до и после предварительной обработки.

### B. Настройка графовой нейронной сети

Компонент ST-GNN использует входное окно длительностью 60 минут, один слой графовой свертки с 16 скрытыми нейронами, GRU с 32 скрытыми нейронами, 10 эпох обучения и скорость обучения  $10^{-3}$ .

Анализ рассматривает временные профили оценок аномальности, число и частоту обнаруженных аномалий, средние значения оценок аномальности и качественное сравнение двух ветвей обнаружения.

ТАБЛИЦА III.

Параметр	Значение
Входное окно	60 мин
Скрытые нейроны GCN	16
Скрытые нейроны GRU	32
Эпохи обучения	10
Скорость обучения	1e-3

## V. РЕЗУЛЬТАТЫ И ОБСУЖДЕНИЕ

Компонент на основе статистических правил выявляет резкие изменения параметров среды. Как показано на рис. 1, оценка демонстрирует локализованную область повышенных значений, когда наблюдаемые измерения отклоняются от своего локального статистического фона. Такое поведение ожидаемо, поскольку скользящая медиана и

нормализация на основе MAD выделяют отклонения от локального статистического фона. Когда несколько связанных датчиков отклоняются одновременно, механизм распространения по графу усиливает аномальный сигнал, позволяя детектору выявлять согласованные возмущения среды. Компонент ST-GNN характеризуется более плавным поведением и формирует меньшее число более концентрированных пиков (рис. 1). Поскольку эта ветвь основана на ошибке прогноза, она наиболее чувствительна тогда, когда возмущения сохраняются достаточно долго, чтобы нарушить усвоенную временную динамику системы. В результате нейросетевой детектор делает акцент на нерегулярностях большей длительности, а не на изолированных всплесках. Этим объясняется, почему ветвь ST-GNN выявляет меньше аномалий по сравнению с детектором на основе правил.

На рис. 1 напрямую сопоставлены оценки, формируемые двумя компонентами. Табл. IV отражает число аномалий, выявленных двумя компонентами.




Рис. 1. Сравнение результатов оценок двух компонент на основе правил и ветви ST-GNN

## VI. ОБСУЖДЕНИЕ И ЗАКЛЮЧЕНИЕ

В работе представлен гибридный подход к обнаружению нарушений сна на основе анализа данных об окружающей среде. Его отличительной особенностью является комбинация двух компонент: статистического, построенного на робастном статистическом оценивании с распространением оценок с учетом графа связей между сенсорами, и пространственно-временного компонента, представленного графовой нейронной сетью, моделирующую временную динамику в многомерных сенсорных данных.

Экспериментальные результаты подчеркивают комплементарные роли двух компонент. Статистический модуль значительно «реагирует» на внезапные изменения среды, что делает его эффективным для выявления кратковременных возмущений, а модель нейросетевого прогнозирования фокусируется на отклонениях от усвоенных временных паттернов и

потому лучше улавливает нерегулярности большей длительности. Совместно эти компоненты обеспечивают более полное представление об аномалиях среды, чем любой из подходов по отдельности. С учетом того, что использованный в исследовании набор данных не содержал размеченных данных, было выполнено исследовательский анализ данных, который показал пересечение результатов каждого из компонента.

ТАБЛИЦА IV.

Метод	Обнаруженные аномалии	Частота обнаружения	Средняя оценка
Ветвь на основе правил	8	0.0279%	0.3801
Ветвь ST-GNN	5	0.0175%	0.0127

В дальнейшей работе планируется валидация предложенной схемы на наборах данных с аннотированными нарушениями сна, а также исследование адаптивных методов автоматического обучения связей между датчиками.

## СПИСОК ЛИТЕРАТУРЫ

- [1] J. Liu, M. Chen, and Y. Chen, "Smart home-based sleep monitoring using ambient sensors," *IEEE J. Biomed. Health Informat.*, 2019.
- [2] P. Dawadi, D. Cook, and M. Schmitter-Edgecombe, "Automated cognitive health assessment using smart home monitoring of complex tasks," *IEEE Trans. Syst., Man, Cybern. Syst.*, vol. 43, no. 6, pp. 1302-1313, 2013.
- [3] V. Chandola, A. Banerjee, and V. Kumar, "Anomaly detection: A survey," *ACM Comput. Surv.*, vol. 41, no. 3, Art. no. 15, 2009.
- [4] T. N. Kipf and M. Welling, "Semi-supervised classification with graph convolutional networks," in *Proc. Int. Conf. Learn. Represent. (ICLR)*, 2017.
- [5] B. Yu, H. Yin, and Z. Zhu, "Spatio-temporal graph convolutional networks: A deep learning framework for traffic forecasting," in *Proc. Int. Joint Conf. Artif. Intell. (IJCAI)*, 2018, pp. 3634-3640.
- [6] Y. Zhao, R. Zhang, and H. Chen, "Multivariate Time-Series Anomaly Detection via Graph Attention Network (MTAD-GAT)," *Proc. IEEE Int. Conf. Data Mining*, 2020.
- [7] A. Deng and B. Hooi, "Graph Neural Network-Based Anomaly Detection in Multivariate Time Series," *Proc. AAAI Conf. Artificial Intelligence*, 2021.
- [8] Y. Li, J. Chen, and Z. Zhao, "StackVAE-G: An Efficient and Interpretable Model for Multivariate Time Series Anomaly Detection," 2021.
- [9] P. Ray et al., "Learning Graph Neural Networks for Multivariate Time Series Anomaly Detection," 2021.
- [10] Z. Chen et al., "Learning Graph Structures with Transformer for Multivariate Time Series Anomaly Detection," 2021.