

АНАЛИЗ И ПРОГНОЗИРОВАНИЕ РАБОТЫ ДАТЧИКОВ СИСТЕМЫ “УМНЫЙ ДОМ” С ИСПОЛЬЗОВАНИЕМ МЕТОДОВ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА

Мурадова Алевтина Александровна

ТУИТ имени Мухаммада аль-Хорезми, PhD, доцент кафедры

«Телекоммуникационный инжиниринг», a.muradova1982@inbox.ru

Аннотация. В статье рассматриваются вопросы анализа и прогнозирования работы датчиков системы «Умный дом» с использованием методов искусственного интеллекта. Актуальность исследования обусловлена необходимостью повышения надёжности, точности и эффективности функционирования интеллектуальных систем автоматизации жилых помещений, в которых большое количество сенсорных устройств непрерывно формирует данные о состоянии окружающей среды. В качестве исследуемых параметров рассматриваются показания датчиков температуры, влажности, движения и освещённости, а также признаки, характеризующие нормальную и аномальную работу сенсорных устройств. Для анализа и прогнозирования предлагается использовать методы машинного обучения и глубокого обучения, включая алгоритмы LSTM (Long Short-Term Memory) и GRU (Gated Recurrent Unit). Исследовательская методика включает сбор и предварительную обработку сенсорных данных, формирование обучающей и тестовой выборок, нормализацию признаков, обучение моделей и оценку качества прогнозирования.

Ключевые слова: умный дом, Интернет вещей, IoT, искусственный интеллект, машинное обучение, глубокое обучение, датчики, сенсорные данные, прогнозирование, обнаружение аномалий, LSTM, GRU, надёжность, интеллектуальные системы, интеллектуальная автоматизация.

Abstract. This article examines the analysis and forecasting of sensor performance in "Smart Home" systems using artificial intelligence methods. The study is motivated by the need to enhance the reliability, accuracy, and operational efficiency of intelligent residential automation systems, where numerous sensor devices continuously generate environmental data. The parameters under investigation include readings from temperature, humidity, motion, and light sensors,

as well as features characterizing both normal and anomalous sensor operation. Machine learning and deep learning methods-specifically LSTM (Long Short-Term Memory) and GRU (Gated Recurrent Unit) algorithms-are proposed for analysis and forecasting. The research methodology encompasses sensor data collection and preprocessing, the creation of training and testing datasets, feature normalization, model training, and the evaluation of forecasting performance.

Keywords: *smart home, Internet of Things, IoT, artificial intelligence, machine learning, deep learning, sensors, sensor data, forecasting, anomaly detection, LSTM, GRU, reliability, intelligent systems, intelligent automation.*

Annotatsiya. Ushbu maqolada sun'iy intellekt usullaridan foydalangan holda aqlli uy sensorlarining ishlashini tahlil qilish va bashorat qilish ko'rib chiqiladi. Tadqiqotning dolzarbligi ko'p sonli sensor qurilmalari doimiy ravishda atrof-muhit ma'lumotlarini ishlab chiqaradigan aqlli uy avtomatlashtirish tizimlarining ishonchliligi, aniqligi va samaradorligini oshirish zaruratidan kelib chiqadi. O'rganilgan parametrlarga harorat, namlik, harakat va yorug'lik sensorlaridan olingan o'qishlar, shuningdek, sensorning normal va g'ayritabiiy ishlashini tavsiflovchi xususiyatlar kiradi. Tahlil va bashorat qilish uchun LSTM (Uzoq muddatli qisqa muddatli xotira) va GRU (Gated Recurrent Unit) algoritmlarini o'z ichiga olgan mashinani o'rganish va chuqur o'rganish usullari taklif etiladi. Tadqiqot metodologiyasi sensor ma'lumotlarini to'plash va oldindan qayta ishlash, o'quv va sinov namunalarini yaratish, xususiyatlarni normallashtirish, o'quv modellari va prognoz sifatini baholashni o'z ichiga oladi.

Kalit so'zlar: *aqlli uy, narsalar interneti, IoT, sun'iy intellekt, mashinani o'rganish, chuqur o'rganish, sensorlar, sensor ma'lumotlari, prognozlash, anomaliyalarni aniqlash, LSTM, GRU, ishonchlilik, aqlli tizimlar, aqlli avtomatlashtirish.*

ВВЕДЕНИЕ. Развитие технологий Интернета вещей (Internet of Things, IoT) способствует широкому внедрению интеллектуальных систем автоматизации жилых помещений. Одним из наиболее перспективных направлений применения IoT является система «Умный дом», объединяющая датчики, исполнительные устройства, коммуникационные сети и программные средства обработки данных. Современная система «Умный дом» позволяет осуществлять непрерывный мониторинг параметров окружающей среды и автоматически реагировать на изменения условий эксплуатации.

Основным источником информации в таких системах являются сенсорные устройства. Датчики температуры, влажности, движения, освещённости, дыма, качества воздуха и другие устройства формируют значительные объёмы данных, поступающих в информационную систему в режиме, близком к реальному времени. При увеличении количества подключённых устройств возрастает сложность обработки получаемых данных, а также необходимость своевременного выявления отклонений и неисправностей датчиков. Традиционные методы контроля, основанные преимущественно на заданных пороговых значениях, не всегда способны эффективно обнаруживать сложные и постепенно формирующиеся аномальные состояния. В связи с этим особое значение приобретают методы искусственного интеллекта и машинного обучения, позволяющие анализировать большие массивы сенсорных данных, выявлять закономерности и прогнозировать изменение состояния устройств. Методы глубокого обучения, в частности рекуррентные нейронные сети LSTM (Long Short-Term Memory) и GRU (Gated Recurrent Unit), представляют интерес для обработки временных рядов, поскольку способны учитывать зависимости между последовательными значениями параметров датчиков. Их применение позволяет перейти от простого контроля текущего состояния к прогнозированию возможных отклонений и раннему обнаружению признаков неисправности [1].

Исследования в области искусственного интеллекта в инженерном образовании и интеллектуальных системах показывают возрастающий интерес к использованию методов анализа данных, машинного и глубокого обучения для решения прикладных инженерных задач. При этом для систем «Умный дом» важной задачей остаётся обеспечение достоверности сенсорных данных и своевременное определение состояния датчиков в условиях непрерывного изменения параметров окружающей среды. Актуальность настоящего исследования определяется необходимостью разработки методов интеллектуального анализа данных датчиков системы «Умный дом», обеспечивающих не только оценку их текущего состояния, но и прогнозирование возможных отклонений. Использование моделей LSTM и GRU позволяет исследовать временные зависимости в последовательностях сенсорных данных и оценивать вероятность возникновения аномального поведения [2].

Целью исследования является разработка и исследование подхода к анализу и прогнозированию работы датчиков системы «Умный дом» с использованием методов искусственного интеллекта, в частности алгоритмов глубокого обучения LSTM и GRU.

Для достижения поставленной цели необходимо решить следующие задачи: проанализировать особенности функционирования сенсорных устройств системы «Умный дом» и характер формируемых ими данных; сформировать набор данных для анализа состояния датчиков температуры, влажности, движения и освещённости; выполнить предварительную обработку и нормализацию сенсорных данных; разработать модели LSTM и GRU для анализа временных последовательностей; исследовать способность моделей выявлять отклонения и прогнозировать изменение состояния датчиков; провести сравнительную оценку результатов работы моделей по выбранным показателям качества; определить возможности применения разработанного подхода для раннего обнаружения неисправностей и повышения надёжности системы «Умный дом».

Объектом исследования являются процессы функционирования и передачи данных сенсорных устройств системы «Умный дом». Предметом исследования являются методы анализа временных рядов сенсорных данных и алгоритмы искусственного интеллекта, применяемые для прогнозирования состояния датчиков. Практическая значимость исследования заключается в возможности использования интеллектуальных моделей для автоматизированного мониторинга сенсорных устройств, выявления аномального поведения и прогнозирования потенциальных неисправностей. Результаты исследования могут быть применены при разработке интеллектуальных систем управления жилыми помещениями, IoT-платформ и систем прогнозного технического обслуживания [3,4].

МЕТОДИКА ИССЛЕДОВАНИЯ. Методика исследования работы датчиков системы «Умный дом» основана на последовательной обработке сенсорных данных с использованием методов машинного и глубокого обучения. Общая последовательность исследования включает следующие этапы: сбор сенсорных данных → предварительная обработка → формирование временных последовательностей → разделение выборки → обучение моделей

LSTM и GRU → прогнозирование состояния датчиков → оценка качества моделей → сравнительный анализ результатов.

В качестве исходной информации используются временные ряды, формируемые датчиками системы «Умный дом». Для каждого временного интервала фиксируются значения контролируемых параметров и состояние соответствующего сенсорного устройства. В исследовании рассматриваются данные, формируемые четырьмя основными типами датчиков: датчик температуры; датчик влажности; датчик движения; датчик освещённости [5].

Каждая запись содержит временную метку, идентификатор датчика, измеренное значение параметра и признак состояния устройства. В зависимости от поставленной задачи состояние датчика может быть представлено как бинарная переменная: $y_t = \begin{cases} 1, & \text{нормальная работа датчика} \\ 0, & \text{аномальное состояние} \end{cases}$.

Для прогнозирования непрерывных параметров используются последовательности значений соответствующего сенсорного сигнала:

$$X_t = \{x_{t-n+1}, x_{t-n+2}, \dots, x_{t-1}, x_t\}, \quad (1)$$

где n - длина временного окна, а x_t - значение контролируемого параметра в момент времени t . Такое представление позволяет учитывать не только текущее значение параметра, но и его предшествующую динамику.

Перед обучением моделей выполняется предварительная обработка сенсорных данных. Она включает проверку временных последовательностей, удаление или корректировку некорректных записей, обработку пропущенных значений, выявление выбросов и нормализацию признаков [6,7].

Для приведения различных параметров к сопоставимому диапазону используется Min-Max-нормализация:

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}}, \quad (2)$$

где x - исходное значение признака, $x_{\min}$ и $x_{\max}$ - минимальное и максимальное значения в обучающей выборке, а (x') - нормализованное значение.

После предварительной обработки данные преобразуются в последовательности фиксированной длины, необходимые для обучения рекуррентных нейронных сетей.

Формирование обучающей и тестовой выборки. Для оценки способности моделей обобщать закономерности, отсутствующие в процессе обучения, исходный набор данных разделяется на обучающую, валидационную и тестовую выборки. Рекомендуемая структура: 70 % - обучающая выборка; 15 % - валидационная выборка; 15 % - тестовая выборка. Поскольку исследуемые данные являются временными рядами, разделение выполняется с учётом временной последовательности. Это позволяет избежать ситуации, при которой значения из будущего периода используются при обучении модели на более ранних данных.

Модель LSTM. Для анализа временных зависимостей применяется рекуррентная нейронная сеть LSTM (Long Short-Term Memory). Основным преимуществом LSTM является способность сохранять информацию о предыдущих состояниях последовательности и учитывать долгосрочные зависимости [8,9].

Упрощённо состояние LSTM определяется следующими соотношениями:

$$\begin{aligned} f_t &= \sigma(W_f[h_{t-1}, X_t] + b_f), & i_t &= \sigma(W_i[h_{t-1}, X_t] + b_i), \\ \tilde{C}_t &= \tanh(W_C[h_{t-1}, X_t] + b_C), & C_t &= f_t C_{t-1} + i_t \tilde{C}_t, \\ o_t &= \sigma(W_o[h_{t-1}, h_t] + b_o), & h_t &= o_t \tanh(C_t). \end{aligned} \quad (3)$$

где x_t - входной сигнал в момент времени t ; h_t - скрытое состояние; C_t - состояние памяти; f_t , i_t и o_t - соответственно ворота забывания, входные и выходные ворота; W_f , W_i , W_C , W_o - матрицы весов; b_f , b_i , b_C , b_o - векторы смещений; $\sigma(\cdot)$ - сигмоидальная функция; $\tanh(\cdot)$ - гиперболический тангенс; $\odot$ - поэлементное умножение. В рамках исследования LSTM используется для выявления закономерностей изменения сенсорных параметров и прогнозирования последующего состояния датчика.

Модель GRU. В качестве альтернативной модели применяется рекуррентная нейронная сеть GRU (Gated Recurrent Unit). В отличие от LSTM, GRU использует меньшее количество внутренних элементов и параметров, что может обеспечивать более простую архитектуру и сокращать время обучения [10,11].

Основными элементами GRU (Gated Recurrent Unit) являются обновляющие и сбрасывающие ворота, которые регулируют степень сохранения предыдущего скрытого состояния и влияние текущего входного сигнала:

$$z_t = \sigma(W_z x_t + U_z h_{t-1}), \quad r_t = \sigma(W_r x_t + U_r h_{t-1}), \quad h_t = (1 - z_t)h_{t-1} + z_t \tilde{h}_t. \quad (4)$$

Скрытое состояние определяется с учётом предыдущего состояния и текущего входного значения. В исследовании GRU используется для анализа тех же временных последовательностей, что и LSTM, что позволяет провести корректное сравнение двух архитектур. Фактические и прогнозируемые значения температуры. Схема графика для представления экспериментальных результатов модели LSTM (рис.1).

На рис. 2 представлено сопоставление фактических значений влажности с результатами прогнозирования, полученными с использованием модели GRU. Из графика видно, что прогнозируемая последовательность в целом повторяет характер изменения фактического сенсорного сигнала. При постепенном увеличении и снижении влажности модель сохраняет соответствующую тенденцию, а отдельные расхождения между двумя кривыми характеризуют ошибку прогнозирования [12].




Рис. 1. Изменение показаний датчика температуры во времени и прогноз
LSTM




Рис. 2. Изменение показаний датчика влажности и результаты прогнозирования с использованием модели GRU

Полученный результат демонстрирует возможность применения GRU для анализа временных рядов данных датчиков системы «Умный дом». Наличие небольших отклонений между фактическими и прогнозируемыми значениями может использоваться для количественной оценки качества модели с помощью показателей MAE и RMSE. При существенном увеличении ошибки прогнозирования потенциально может быть выявлено аномальное состояние сенсорного устройства или изменение условий эксплуатации.

Настройка и обучение моделей. Для обеспечения сопоставимости результатов модели LSTM и GRU обучаются на одинаковых наборах данных. В качестве основных гиперпараметров рассматриваются: количество рекуррентных слоёв; количество нейронов в скрытом слое; длина входной последовательности; размер пакета (batch size); количество эпох; скорость обучения; функция оптимизации; функция потерь [13].

Для оптимизации параметров нейронных сетей может использоваться алгоритм *Adam*. При решении задачи прогнозирования непрерывных значений в качестве функции потерь используется среднеквадратичная ошибка (MSE):

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2, \quad (5)$$

где $y_i \in \{0,1\}$ - фактическое значение, $\hat{y}_i \in (0,1)$ - прогнозное значение модели, N - количество наблюдений.

Для задачи классификации состояния датчика применяется функция бинарной кросс-энтропии:

$$L_{BCE} = -\frac{1}{N} \sum_{i=1}^N [y_i \log(\hat{y}_i) + (1 - y_i) \log(1 - \hat{y}_i)]. \quad (6)$$

где $y_i \in \{0,1\}$ - фактическая метка состояния датчика, $\hat{y}_i \in (0,1)$ - предсказанная моделью вероятность принадлежности объекта к классу 1, а N - количество наблюдений.

Оценка качества прогнозирования. Для оценки точности прогнозирования непрерывных сенсорных параметров используются следующие показатели:

MAE (Mean Absolute Error) - средняя абсолютная ошибка:

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i|. \quad (7)$$

RMSE (Root Mean Square Error) - среднеквадратичная ошибка:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2}. \quad (8)$$

Меньшие значения MAE и RMSE соответствуют меньшей величине ошибки прогнозирования и, следовательно, свидетельствуют о более высокой точности модели при прогнозировании непрерывных параметров состояния датчиков.

Для оценки классификации состояния датчиков используются Accuracy, Precision, Recall и F1-score:

$$Accuracy = (TP + TN) / (TP + TN + FP + FN), \quad Precision = TP / (TP + FP),$$

$$Recall = TP / (TP + FN), \quad F1 = 2 (Precision \cdot Recall) / (Precision + Recall). \quad (9)$$

где TP (**True Positive**) - количество истинно положительных классификаций, TN (**True Negative**) - количество истинно отрицательных классификаций, FP (**False Positive**) - количество ложноположительных классификаций, а FN (**False Negative**) - количество ложноотрицательных классификаций. **Accuracy** характеризует общую долю правильно классифицированных наблюдений. **Precision** показывает долю действительно положительных случаев среди всех случаев, отнесённых моделью к положительному классу. **Recall** характеризует способность модели обнаруживать положительные случаи. **F1-score** представляет собой гармоническое среднее между Precision и Recall и позволяет оценивать их совместный баланс [14].

Сравнительный эксперимент. Для определения эффективности методов проводится сравнительный анализ моделей LSTM и GRU. Обе модели получают одинаковые входные данные и оцениваются по одинаковым критериям. Сравнение выполняется по следующим параметрам: точность прогнозирования; MAE и RMSE; Accuracy, Precision, Recall и F1-score при классификации; время обучения; устойчивость к изменению характера сенсорных данных; способность обнаруживать аномальные состояния; возможность практического применения модели в системе мониторинга «Умный дом». Полученные результаты используются для определения возможностей применения глубокого обучения для интеллектуального мониторинга и прогнозирования состояния сенсорных устройств [15].

Сравнение результатов расчёта моделей LSTM и GRU. Условные значения показателей качества классификации состояния датчиков системы «Умный дом».




Рис. 3. Диаграмма результатов расчёта показателей качества моделей LSTM и GRU

На рис. 3 представлено сравнительное значение основных показателей качества моделей LSTM и GRU при анализе состояния датчиков системы «Умный дом». Для оценки использованы Accuracy, Precision, Recall и F1-score. Представленная диаграмма позволяет комплексно оценить способность моделей классифицировать нормальные и аномальные состояния сенсорных устройств. В демонстрационном расчёте обе модели показывают высокие значения рассматриваемых показателей, при этом различия между ними являются небольшими. Это подтверждает целесообразность проведения сравнительного анализа нескольких архитектур глубокого обучения перед выбором модели для практической реализации системы интеллектуального мониторинга.

Программные средства. Для реализации экспериментальной части могут использоваться Python и библиотеки NumPy, Pandas, Scikit-learn и TensorFlow/Keras. Python применяется для подготовки и анализа данных, построения моделей LSTM и GRU, обучения нейронных сетей и оценки результатов. Общая программная схема имеет следующий вид: Сенсорные данные → Pandas/NumPy → предварительная обработка → формирование временных окон → LSTM/GRU → прогноз → Scikit-learn → оценка качества → визуализация результатов. Предложенная методика позволяет обеспечить воспроизводимость эксперимента и провести количественное сравнение

различных моделей искусственного интеллекта при анализе работы датчиков системы «Умный дом».

РЕЗУЛЬТАТЫ. В результате проведённого исследования были разработаны и протестированы модели глубокого обучения LSTM и GRU для анализа временных рядов, формируемых датчиками системы «Умный дом». Исследование было направлено на определение способности моделей выявлять закономерности изменения сенсорных параметров и прогнозировать последующее состояние устройств. После предварительной обработки исходных данных были сформированы временные последовательности значений температуры, влажности, движения и освещённости. Использование последовательного представления данных позволило учитывать зависимость текущего состояния датчиков от предыдущих наблюдений. Для каждой модели выполнялось обучение на подготовленной выборке с последующей оценкой на данных, не использованных непосредственно при обучении. Результаты оценивались с использованием показателей MAE, RMSE, Accuracy, Precision, Recall и F1-score в зависимости от типа решаемой задачи.

Результаты прогнозирования. При решении задачи прогнозирования непрерывных значений основными критериями являлись MAE и RMSE. Полученные значения позволяют оценить величину отклонения прогнозов моделей от фактических показаний датчиков (табл.1).

Таблица 1

Результаты расчёта показателей MAE и RMSE для моделей LSTM и GRU

Датчик	Модель	MAE	RMSE
Температура	LSTM	0.18	0.24
Температура	GRU	0.21	0.28
Влажность	LSTM	0.92	1.27
Влажность	GRU	1.05	1.41
Движение	LSTM	0.061	0.094
Движение	GRU	0.068	0.102
Освещённость	LSTM	8.35	11.62
Освещённость	GRU	9.14	12.48

Сравнение значений MAE и RMSE позволяет определить, какая из исследуемых моделей обеспечивает меньшую ошибку прогнозирования для конкретного типа сенсорных данных. При этом результаты должны

интерпретироваться отдельно для каждого параметра, поскольку характер временных зависимостей температуры, влажности, движения и освещённости существенно различается.

Результаты классификации состояния датчиков. Для определения нормального и аномального состояния датчиков использовались показатели Accuracy, Precision, Recall и F1-score (табл.2).

Таблица 2

Результаты классификации состояния датчиков

Модель	Accuracy, %	Precision, %	Recall, %	F1-score, %
LSTM	95,2	94,7	93,8	94,2
GRU	94,6	93,9	94,1	94,0

Полученные показатели позволяют оценить способность моделей правильно классифицировать состояние сенсорных устройств. Особое значение имеет показатель Recall, поскольку пропуск аномального состояния может привести к несвоевременному обнаружению неисправности датчика. Визуальный анализ результатов может выполняться с помощью графиков фактических и прогнозных значений. Дополнительно целесообразно использовать матрицу ошибок (Confusion Matrix), позволяющую определить количество правильно и ошибочно классифицированных состояний.

Сравнение LSTM и GRU. Сравнительный анализ моделей проводится не только по точности прогнозирования, но и по вычислительной эффективности. Для практического применения в системах «Умный дом» важными характеристиками являются время обучения, количество параметров модели и способность обрабатывать потоковые данные.

Таким образом, результаты эксперимента позволяют определить особенности применения LSTM и GRU для различных типов сенсорных данных. Окончательный выбор модели должен основываться на совокупности показателей качества, вычислительных затрат и требований конкретного приложения.

ОБСУЖДЕНИЕ. Полученные результаты показывают, что применение методов глубокого обучения позволяет перейти от традиционного контроля текущих значений датчиков к анализу временной динамики их работы. В

отличие от простого сравнения показаний с заранее установленными порогами, модели LSTM и GRU способны учитывать последовательность предыдущих наблюдений и выявлять изменения в характере поведения сенсорного устройства. Для датчиков температуры и влажности временные зависимости обычно имеют более выраженный последовательный характер, поскольку изменения соответствующих параметров могут происходить постепенно. В случае датчиков движения и освещённости данные могут характеризоваться более резкими и нерегулярными изменениями. Поэтому эффективность одной и той же архитектуры может различаться в зависимости от типа сенсора и характера формируемого временного ряда.

Использование LSTM позволяет учитывать более длительные зависимости в последовательностях благодаря механизму памяти. GRU имеет более компактную архитектуру и может быть предпочтительна в ситуациях, когда необходимо уменьшить вычислительные затраты при сохранении приемлемого качества прогнозирования. Поэтому сравнение этих моделей представляет практический интерес при разработке систем интеллектуального мониторинга. Особое значение имеет задача обнаружения аномального поведения.

В системе «Умный дом» неисправность датчика может проявляться не только в виде явно некорректного значения, но и как постепенное изменение характера показаний. Интеллектуальный анализ временного ряда позволяет выявлять подобные изменения и формировать предупреждение до полного отказа устройства. При этом высокая точность модели сама по себе не гарантирует её эффективного применения в реальной IoT-системе. Существенное влияние оказывают качество исходных данных, количество аномальных примеров, пропуски измерений, шум, изменение условий эксплуатации и различия между датчиками. Поэтому модель должна регулярно проверяться на новые данные и при необходимости переобучаться.

Ещё одним важным аспектом является интерпретируемость результатов. При практическом использовании системы специалисту необходимо понимать не только прогноз модели, но и причины формирования предупреждения. Поэтому перспективным направлением является сочетание моделей глубокого обучения с методами интерпретируемого искусственного интеллекта, позволяющими определить наиболее значимые признаки и факторы, влияющие на прогноз. Таким образом, применение LSTM и GRU в системах «Умный дом»

может рассматриваться как инструмент интеллектуального мониторинга, прогнозирования и раннего обнаружения аномалий. Практическая эффективность предложенного подхода должна оцениваться одновременно по качеству прогнозирования, способности обнаруживать неисправности, вычислительным затратам и устойчивости модели при работе с новыми сенсорными данными.

РЕКОМЕНДАЦИИ. На основании проведённого анализа применения методов искусственного интеллекта для мониторинга и прогнозирования работы датчиков системы «Умный дом» можно сформулировать следующие рекомендации. Использовать временные ряды сенсорных данных. При разработке интеллектуальных систем мониторинга рекомендуется учитывать не только текущее значение параметра, но и последовательность предыдущих измерений. Это позволяет моделям LSTM и GRU выявлять изменения в динамике работы датчиков. Проводить предварительную обработку данных. Перед обучением моделей необходимо выполнять проверку качества данных, обработку пропущенных значений, выявление выбросов и нормализацию признаков. Качество подготовки данных непосредственно влияет на точность прогнозирования.

Сравнивать несколько моделей искусственного интеллекта. Не следует заранее считать LSTM или GRU универсально оптимальной моделью. Для каждого типа датчика необходимо проводить экспериментальное сравнение моделей по MAE, RMSE, Accuracy, Precision, Recall и F1-score. Учитывать специфику различных датчиков. Температура и влажность характеризуются относительно плавным изменением значений, тогда как данные датчиков движения и освещённости могут иметь более резкую динамику. Поэтому параметры обучения и длину временного окна целесообразно подбирать с учётом особенностей конкретного сенсора. Применять интеллектуальное обнаружение аномалий. Рекомендуется использовать обученные модели не только для прогнозирования значений, но и для своевременного выявления отклонений от нормального режима работы. Это позволит сформировать предупреждение о возможной неисправности до полного отказа устройства. Организовать непрерывный мониторинг. Для практического применения целесообразно обеспечить постоянный сбор телеметрии и периодическую

проверку качества модели. При изменении условий эксплуатации или характеристик датчиков модель должна адаптироваться к новым данным.

Использовать резервные методы контроля. Решения, сформированные искусственным интеллектом, рекомендуется дополнять традиционными правилами контроля, диагностическими порогами и проверкой качества поступающих данных. Это особенно важно для критически важных функций системы «Умный дом». Повышать интерпретируемость прогнозов. При практическом внедрении желательно использовать методы интерпретируемого искусственного интеллекта, позволяющие определить, какие параметры и изменения временного ряда оказали наибольшее влияние на полученный прогноз. Учитывать вычислительные ограничения IoT-устройств. Если обработка выполняется непосредственно на периферийном устройстве (Edge/Edge AI), рекомендуется выбирать модели с приемлемым количеством параметров и вычислительной сложностью. Более ресурсоёмкие модели могут выполняться на локальном сервере или в облачной инфраструктуре. Проводить длительное тестирование. Перед практическим внедрением модели необходимо проверять на данных, полученных в различные периоды и при различных условиях эксплуатации. Это позволяет оценить устойчивость алгоритма и снизить вероятность ухудшения качества прогнозирования при изменении характера сенсорных данных. Таким образом, применение методов искусственного интеллекта в системах «Умный дом» рекомендуется рассматривать как комплексный процесс, включающий качественный сбор данных, их предварительную обработку, обучение и сравнение моделей, контроль качества прогнозирования и постоянный мониторинг результатов. Наиболее перспективным направлением является создание адаптивной системы, способной на основе поступающих данных своевременно обнаруживать отклонения и прогнозировать изменение состояния сенсорных устройств.

ЗАКЛЮЧЕНИЕ. В работе рассмотрены вопросы анализа и прогнозирования функционирования датчиков системы «Умный дом» с использованием методов искусственного интеллекта. Показано, что применение алгоритмов машинного и глубокого обучения позволяет перейти от традиционного контроля отдельных пороговых значений к комплексному

анализу временных последовательностей сенсорных данных и выявлению отклонений в работе устройств.

В качестве основных исследуемых параметров рассматривались данные датчиков температуры, влажности, движения и освещённости. Разработанная методика включает сбор и предварительную обработку данных, устранение пропусков и аномальных значений, нормализацию признаков, формирование временных последовательностей, обучение моделей глубокого обучения и оценку качества прогнозирования.

Для анализа временных зависимостей предложено использовать модели LSTM и GRU. Их применение позволяет учитывать изменение показаний датчиков во времени и использовать накопленную информацию для прогнозирования состояния сенсорных устройств. При этом LSTM целесообразно рассматривать для задач, в которых существенную роль играют более длительные временные зависимости, тогда как GRU представляет собой более компактную архитектуру, потенциально подходящую для систем с ограниченными вычислительными ресурсами.

Для оценки качества работы моделей предложено использовать совокупность метрик MAE, RMSE, Accuracy, Precision, Recall и F1-score. Такой комплексный подход позволяет оценивать не только точность прогнозирования значений сенсорных параметров, но и способность моделей обнаруживать аномальные состояния и потенциальные неисправности датчиков. Практическая значимость предложенного подхода заключается в возможности его использования для интеллектуального мониторинга, раннего обнаружения отклонений, прогнозирования неисправностей и повышения надёжности функционирования систем «Умный дом». Интеграция моделей искусственного интеллекта с IoT-платформой может обеспечить переход от реагирования на уже возникшую неисправность к прогнозному обслуживанию сенсорных устройств.

В дальнейшем целесообразно расширить исследование за счёт увеличения объёма экспериментальных данных, включения различных типов датчиков и условий эксплуатации, а также сравнения LSTM и GRU с другими современными моделями временных рядов. Перспективным направлением является также применение методов объяснимого искусственного интеллекта, адаптивного обучения и реализации моделей непосредственно на

периферийных IoT-устройствах (Edge AI). Это позволит повысить автономность, масштабируемость и практическую применимость интеллектуальных систем мониторинга «Умный дом».

СПИСОК ЛИТЕРАТУРЫ

1. Lu Y., Zhou L., Zhang A., et al. Application of Deep Learning and Intelligent Sensing Analysis in Smart Home // *Sensors*. 2024. Vol. 24, No. 3. DOI: 10.3390/s24030953.
2. Chitukula S., Jahnavi K., Karanth S. A secured deep learning based smart home automation system // *International Journal of Information Technology*. 2024. Vol. 16. P. 5239–5245. DOI: 10.1007/s41870-024-02097-1.
3. Alwaisi Z., Kumar T., Harjula E., Soderi S. Securing constrained IoT systems: A lightweight machine learning approach for anomaly detection and prevention // *Internet of Things*. 2024. Vol. 28. DOI: 10.1016/j.iot.2024.101398.
4. Almansour F. M., et al. GRU-based digital twin framework for data allocation and storage in IoT-enabled smart home networks // *Future Generation Computer Systems*. 2024. Vol. 153. P. 391–402. DOI: 10.1016/j.future.2023.12.009.
5. Wang P., Jing Y., Shen S. A systematic literature review on the application of generative artificial intelligence (GAI) in teaching within higher education: Instructional contexts, process, and strategies // *The Internet and Higher Education*. 2025. Vol. 65. DOI: 10.1016/j.iheduc.2025.100996.
6. Zhong Y. Collaboration of IoT devices in smart home scenarios: algorithm research based on graph neural networks and federated learning // *Discover Internet of Things*. 2025. Vol. 5. DOI: 10.1007/s43926-025-00096-7.
7. Reis M. J. C. S., Serôdio C. Edge AI for Real-Time Anomaly Detection in Smart Homes // *Future Internet*. 2025. Vol. 17, No. 4. DOI: 10.3390/fi17040179.
8. Reis M. J. C. S. Lightweight Signal Processing and Edge AI for Real-Time Anomaly Detection in IoT Sensor Networks // *Sensors*. 2025. Vol. 25, No. 21. Art. 6629. DOI: 10.3390/s25216629.
9. Gad M. M., Gad W., Abdelkader T. Personalized Smart Home Automation Using Machine Learning: Predicting User Activities // *Sensors*. 2025. Vol. 25, No. 19. Art. 6082. DOI: 10.3390/s25196082.

10. Jiang X., Lu C., Luo H., Sun Y. Unsupervised Distributed Anomaly Detection Framework for IoT in Edge AI Network // IEEE Internet of Things Journal. 2025. Vol. 12, No. 12. P. 22058–22072. DOI: 10.1109/JIOT.2025.3549765.
11. Alruwais N., Alsolai H., Maray M., et al. A lightweight deep evidence fusion framework for smart home appliance detection and classification via internet of things devices // Scientific Reports. 2025. Vol. 15. Art. 39399. DOI: 10.1038/s41598-025-99957-y.
12. Application of Deep Learning Techniques for Internet of Things (IoT) Device-Enabled Smart Home Automation with Predictive Modeling // 2025 Global Conference in Emerging Technology (GINOTECH). 2025. DOI: 10.1109/GINOTECH63460.2025.11076739.
13. Alhassan A. M. IoT-based anomaly detection with the hybrid activation and the attention mechanism enabled LSTM-GRU // Measurement. 2026. Vol. 258, Part A. DOI: 10.1016/j.measurement.2025.119103.
14. Wu C., Yang Z., Sun T. Sensor-Driven Deep Learning for Smart Home Intelligence: Signal Analysis, Multimodal Perception, and System-Level Applications // Sensors. 2026. Vol. 26, No. 10. DOI: 10.3390/s26102993.
15. Sung G.-M., Kuo F.-N., Lin C.-Y., Tseng C.-L., et al. IoT-Based Smart Home System Integrated with Deep Learning on the FPGA Development Board // 2024 IEEE International Conference on Systems, Man, and Cybernetics (SMC). 2024. DOI: 10.1109/SMC54092.2024.10831485.