



ОТКРЫТАЯ НАУКА
издательство

Международный журнал информационных технологий и энергоэффективности

Сайт журнала:

<http://www.openaccessscience.ru/index.php/ijcse/>



УДК 004

ПРОГНОЗИРОВАНИЕ СБОЕВ IoT-УСТРОЙСТВ ДЛЯ ГИБКОГО ПЛАНИРОВАНИЯ ИХ ТЕХНИЧЕСКОГО ОБСЛУЖИВАНИЯ

Романов Н.А.

ФГБОУ ВО Иркутский национальный исследовательский технический университет, Иркутск, Россия (664074, г. Иркутск, ул. Лермонтова, 83), e-mail: itsacool2014@gmail.com

В данной статье рассматриваются методологии прогнозирования сбоев IoT-устройств. В современном мире Интернет вещей (IoT) стал неотъемлемой частью нашей жизни, проникая в различные сферы, начиная от умного дома и заканчивая промышленностью и здравоохранением. В промышленной сфере выход таких устройств из строя несёт за собой дополнительные расходы, повышенные риски, поэтому задача прогнозирования является наиболее актуальной. Методология прогнозирования сбоев IoT-устройств позволяет повысить надежность и эффективность работы IoT-систем, а также оптимизировать планирование и проведение технического обслуживания. Применение данной методологии может способствовать предотвращению сбоев, минимизации простоев и улучшению качества обслуживания IoT-устройств, внося важный вклад в развитие и расширение IoT-технологий.

Ключевые слова: IoT, прогнозирование, выход из строя, промышленность, датчики, анализ, предсказание, предотвращение, обслуживание оборудования.

PREDICTING FAILURES OF IOT DEVICES FOR FLEXIBLE PLANNING OF THEIR MAINTENANCE

Romanov N.A.

Irkutsk national research technical university, Irkutsk, Russia (664074, Irkutsk, Lermontov str., 83), e-mail: itsacool2014@gmail.com

This article discusses the methodology for predicting failures of IoT devices. In the modern world, the Internet of Things (IoT) has become an integral part of our lives, penetrating into various spheres, from the smart home to industry and healthcare. In the industrial sphere, the failure of such devices entails additional costs, increased risks, so the task of forecasting is the most urgent. The methodology for predicting failures of IoT devices allows you to increase the reliability and efficiency of IoT systems, as well as optimize the planning and maintenance. The application of this methodology can contribute to the prevention of failures, minimize downtime and improve the quality of service of IoT devices, making an important contribution to the development and expansion of IoT technologies.

Keywords: IOT, prediction, failure, industry, sensors, analysis, prediction, prevention, equipment maintenance.

Сегодняшний мир стал свидетелем быстрого развития технологий, которое в значительной мере определяет наш образ жизни и способы взаимодействия с окружающим миром. Одной из самых влиятельных и инновационных технологий последнего времени является концепция интернета вещей (IoT). IoT представляет собой сеть физических устройств, взаимодействующих и обменивающихся данными через интернет без необходимости прямого участия человека. Эта технология перешагнула границы

традиционного компьютерного взаимодействия, расширяя сферу применения информационных технологий на различные объекты нашей повседневной жизни.

Роль IoT в современном мире стала неотъемлемой и разносторонней. IoT-устройства включают в себя все, начиная от умных домашних устройств, таких как умные термостаты, освещение и системы безопасности, и заканчивая сложными системами умных городов, медицинского оборудования, автономных автомобилей и промышленных систем управления. С помощью IoT, реальный мир становится неразрывно связанным с цифровым пространством, позволяя собирать, обрабатывать и анализировать огромные объемы данных из различных источников.

Одной из ключевых проблем, с которой сталкиваются пользователи IoT-устройств, является возникновение сбоев и отказов в их работе. Это может привести к серьезным последствиям, таким как нарушение нормального функционирования систем безопасности, снижение производительности и повреждение оборудования. Поэтому важно разработать методы, позволяющие прогнозировать сбои IoT-устройств, чтобы эффективно планировать их техническое обслуживание и предотвратить возможные проблемы.

Целью данной статьи является рассмотрение методов прогнозирования сбоев IoT-устройств с целью обеспечения гибкого планирования их технического обслуживания. Мы проведем обзор существующих исследований в этой области, проанализируем методологии и алгоритмы, применяемые для прогнозирования сбоев, и представим результаты экспериментов, демонстрирующие эффективность предложенного подхода.

Исследования в области прогнозирования сбоев IoT-устройств имеют важное практическое применение, способствуя повышению эффективности технического обслуживания и минимизации простоев. Результаты данного исследования могут быть полезны как для научного сообщества, так и для промышленности, заинтересованной в оптимизации управления IoT-устройствами.

Методы прогнозирования

Определение методов прогнозирования сбоев IoT-устройств является ключевым аспектом разработки эффективной системы обслуживания. Вот некоторые подробности о нескольких методах прогнозирования неисправностей IoT-устройств:

1. Методы временных рядов.

Методы временных рядов широко применяются для прогнозирования сбоев IoT-устройств. Они основаны на анализе исторических данных временных рядов, чтобы выявить временные закономерности и тренды в поведении устройств. Прогнозы строятся на основе статистических моделей, таких как авторегрессионные интегрированные скользящие средние (ARIMA) или авторегрессионные условные гетероскедастичные (ARCH) модели.

ARIMA (Autoregressive Integrated Moving Average) является одной из наиболее распространенных моделей временных рядов, применяемых для прогнозирования сбоев IoT-устройств. ARIMA модель сочетает в себе три компонента: авторегрессию (AR), интегрирование (I) и скользящее среднее (MA). Авторегрессия учитывает зависимость текущего значения ряда от предыдущих значений, интегрирование позволяет учитывать тренды и стационарность данных, а скользящее среднее учитывает зависимость от ошибок предыдущих прогнозов. Модель ARIMA может быть адаптирована к различным временным рядам путем настройки параметров модели [1].

ARCH (Autoregressive Conditional Heteroskedasticity) является моделью, используемой для моделирования и прогнозирования условной гетероскедастичности во временных рядах. В контексте прогнозирования сбоев IoT-устройств, ARCH модель может быть полезна для обнаружения и предсказания всплесков и колебаний в данных. ARCH модель предполагает, что дисперсия ошибок во временных рядах изменяется в зависимости от предыдущих ошибок, что позволяет учитывать и моделировать различные уровни волатильности [2].

Использование моделей ARIMA и ARCH в методологии прогнозирования сбоев IoT-устройств позволяет учитывать временные зависимости, тренды и условную гетероскедастичность в данных. ARIMA модель способна улавливать и моделировать сложные временные паттерны и поведение, а ARCH модель помогает обнаружить и предсказать возможные всплески или изменения в данных, связанные с сбоями устройств.

Комбинация моделей ARIMA и ARCH с другими методами временных рядов и алгоритмами машинного обучения может значительно улучшить точность и надежность прогнозирования сбоев IoT-устройств, особенно при анализе и прогнозировании временных рядов с переменной дисперсией и сложными зависимостями.

2. Методы машинного обучения.

Методы машинного обучения стали популярными в прогнозировании сбоев IoT-устройств благодаря своей способности обнаруживать сложные зависимости в данных. Эти методы могут использовать различные алгоритмы такие как случайный лес, градиентный бустинг, нейронные сети и методы обучения с подкреплением. Модели машинного обучения обучаются на исторических данных сбоев и их причин, чтобы предсказывать возможные неисправности в будущем. Ниже перечислены основные методы машинного обучения.

Регрессия: Методы регрессии используются для предсказания непрерывных числовых значений. Некоторые из наиболее популярных методов регрессии включают линейную регрессию, логистическую регрессию, полиномиальную регрессию и регрессию опорных векторов (SVR).

Классификация: Методы классификации применяются для разделения данных на заданные категории или классы. Некоторые популярные алгоритмы классификации включают метод ближайших соседей (k-Nearest Neighbors), наивный Байесовский классификатор, метод опорных векторов (SVM), решающие деревья и случайный лес [3].

Кластеризация: Методы кластеризации группируют схожие объекты вместе, не требуя заранее определенных категорий. Некоторые из наиболее распространенных алгоритмов кластеризации включают k-средних (k-Means), иерархическую кластеризацию, DBSCAN и алгоритмы гауссовской смеси.

Методы глубокого обучения: Глубокое обучение основано на искусственных нейронных сетях с несколькими слоями. Такие методы, как сверточные нейронные сети (CNN), рекуррентные нейронные сети (RNN), генеративные состязательные сети (GAN) и рекуррентные сети долгой краткосрочной памяти (LSTM), являются мощными инструментами для обработки изображений, текстовых данных и последовательных данных[5].

Ансамблирование: Методы ансамблирования комбинируют прогнозы нескольких моделей, чтобы получить более точные предсказания. Некоторые популярные методы ансамблирования включают случайный лес, градиентный бустинг (Gradient Boosting) и метод бэггинга (Bagging), случайный лес (Random Forest) [1].

Обучение с подкреплением: Этот метод обучения на основе взаимодействия с окружающей средой. Агент принимает решения и выполняет действия, а затем получает награду или наказание в зависимости от результата. Некоторые алгоритмы обучения с подкреплением включают Q-обучение (Q-Learning) и методы глубокого обучения, такие как Deep Q-Networks (DQN).

Одним из мощных инструментов глубокого обучения, применяемых в этой области, является рекуррентная нейронная сеть, известная как LSTM (Long Short-Term Memory).

LSTM сети представляют собой вид рекуррентных нейронных сетей, способных эффективно обрабатывать последовательные данные с учетом долгосрочных зависимостей. Они особенно полезны при работе с временными рядами, где последовательность событий имеет важное значение. LSTM сети обладают способностью запоминать информацию на протяжении продолжительного временного интервала и выбирать, какую информацию сохранять и какую забывать. Это позволяет им лучше моделировать сложные временные зависимости и предсказывать возможные сбои IoT-устройств.

При применении LSTM в контексте прогнозирования сбоев IoT-устройств, модель может быть обучена на исторических данных о работе устройств и предсказывать возможные сбои в будущем. LSTM сети могут улавливать скрытые паттерны и зависимости, которые не всегда очевидны при использовании традиционных методов прогнозирования. Их способность учитывать долгосрочные зависимости делает их ценным инструментом для прогнозирования сбоев IoT-устройств.

Применение LSTM сетей в методологии прогнозирования сбоев IoT-устройств может существенно улучшить точность и надежность прогнозов, особенно в случаях, когда временные зависимости играют важную роль в процессе. Использование LSTM моделей позволяет более эффективно анализировать и предсказывать события сбоев, способствуя более гибкому и эффективному планированию технического обслуживания IoT-устройств [6].

3. Анализ аномалий.

Анализ аномалий используется для обнаружения и предсказания необычных или отклоняющихся от нормы событий или состояний устройств. Он основан на выявлении аномалий в данных и анализе их связи с возможными сбоями. Алгоритмы анализа аномалий могут использовать методы статистики, машинного обучения или комбинированные подходы для обнаружения неисправностей.

Применение датчиков и диагностических данных:

Использование данных от датчиков и систем диагностики IoT-устройств позволяет отслеживать параметры работы и выявлять изменения, которые могут указывать на возможные сбои. Анализ этих данных может включать мониторинг параметров, распределение данных, изменение показателей производительности и другие характеристики, чтобы предсказывать неисправности и определить оптимальное время для технического обслуживания.

Каждый из этих методов имеет свои преимущества и ограничения, и оптимальный выбор зависит от конкретных требований, доступных данных и особенностей конкретного IoT-устройства или системы. Эффективное прогнозирование сбоев IoT-устройств может быть достигнуто путем комбинации различных методов и использования специализированных моделей, учитывая особенности конкретной проблемы и доступные данные.

Описание методологии прогнозирования сбоев IoT-устройств

Прогнозирование сбоев IoT-устройств является сложной задачей, требующей систематического подхода и использования соответствующих методов. В данной статье предлагается методология прогнозирования сбоев IoT-устройств, основанная на комбинации статистических методов и алгоритмов машинного обучения. Эта методология позволяет эффективно предсказывать возможные неисправности и принимать соответствующие меры по техническому обслуживанию.

Шаг 1: Сбор и предварительная обработка данных

В первом шаге методологии осуществляется сбор и предварительная обработка данных, связанных с работой IoT-устройств. Это может включать в себя сбор и агрегацию данных от датчиков, систем диагностики и журналов событий. Важно провести необходимую предварительную обработку данных, включая очистку от выбросов, заполнение пропущенных значений и приведение данных к подходящему формату.

Шаг 2: Анализ и визуализация данных

После предварительной обработки данных следует провести анализ и визуализацию, чтобы получить представление о характеристиках и паттернах работы IoT-устройств. Это может включать в себя анализ статистических показателей, построение графиков, временных рядов и корреляционного анализа. Цель этого шага - выявить особенности и тренды в данных, которые могут указывать на возможные сбои.

Шаг 3: Выбор и разработка моделей прогнозирования

На основе анализа данных выбираются и разрабатываются подходящие модели прогнозирования сбоев IoT-устройств. Это может включать статистические модели, такие как модели временных рядов (например, ARIMA), или алгоритмы машинного обучения, такие как случайные леса, градиентный бустинг или нейронные сети. Модели обучаются на исторических данных и настраиваются с использованием соответствующих алгоритмов.

Шаг 4: Валидация и тестирование моделей

Для оценки эффективности моделей проводится их валидация и тестирование. Это включает разделение данных на обучающую и тестовую выборки, обучение моделей на обучающих данных и проверку их точности и производительности на тестовых данных. Важно использовать метрики, такие как точность, полнота, F1-меру или среднюю абсолютную ошибку, для оценки качества моделей.

Шаг 5: Реализация и интеграция

После успешной валидации моделей прогнозирования, их необходимо реализовать и интегрировать в систему IoT-устройств. Это может включать разработку программного обеспечения для автоматического мониторинга и прогнозирования сбоев, настройку системы уведомлений или интеграцию с системами управления обслуживанием.

Методология прогнозирования сбоев IoT-устройств позволяет повысить эффективность технического обслуживания и минимизировать простои. Однако, следует отметить, что конкретная реализация методологии может различаться в зависимости от особенностей конкретного проекта и доступных ресурсов.

Список литературы

1. Андрюхин Е.В., Ридли М.К., Правиков Д.И. Прогнозирование сбоев и отказов в распределённых системах управления на основе моделей прогнозирования временных

- рядов // Вопросы кибербезопасности, 2019, №3. С. 24–32. техн. ун-т им. Н.Э. Баумана Москва, 2012. 154 с
2. Шаханов Н.И., Варфоломеев И.А., Ершов Е.В., Юдина О.В. Прогнозирование отказов оборудования в условиях малого количества поломок// Вестник Череповецкого государственного университета, 2016, № 6.С. 36–41.
 3. Имильбаев Р. Р. Методы и алгоритмы прогнозирования значений контролируемых параметров газораспределительной сети по результатам обработки телеметрической информации: дис. канд. техн. наук: Уф. гос. нефт. техн. ун-т Уфа, 2018. 152 с.
 4. Saxena A., Goebel K. Damage propagation modeling for aircraft engine run-to-failure simulation. // 2008 International Conference on Prognostics and Health Management, Denver, CO. 2008. pp. 1–9.
 5. Tibshirani R. J. Regression shrinkage and selection via the lasso // Journal of the Royal Statistical Society. Series B (Methodological), 1996. Vol. 58, No. 1. pp. 267–288.
 6. Hochreiter S. The vanishing gradient problem during learning recurrent neural nets and problem solutions // International Journal of Uncertainty, Fuzziness and Knowledge-Based Systems, 1998. Vol. 6, No 2. pp. 107–116.

References

1. Andriukhin E.V., Ridley M.K., Pravikov D.I. Forecasting failures and failures in distributed control systems based on time series forecasting models // Issues of cybersecurity, 2019, No. 3. pp. 24-32. tech. Bauman Univ., Moscow, 2012. P.154
 2. Shakhonov N.I., Varfolomeev I.A., Ershov E.V., Yudina O.V. Prediction of equipment failures in conditions of a small number of breakdowns// Bulletin of Cherepovets State University, 2016, No. 6.pp. 36-41.
 3. Imelbaev R. R. Methods and algorithms for predicting the values of controlled parameters of the gas distribution network based on the results of processing telemetric information: dis. Candidate of Technical Sciences: Uv. state Oil. tech. Ufa University, 2018. 152 p.
 4. Saxena A., Goebel K. Damage propagation modeling for aircraft engine run-to-failure simulation. // 2008 International Conference on Prognostics and Health Management, Denver, CO. 2008. pp. 1–9.
 5. Tibshirani R. J. Regression shrinkage and selection via the lasso // Journal of the Royal Statistical Society. Series B (Methodological), 1996. Vol. 58, No. 1. pp. 267–288.
 6. Hochreiter S. The vanishing gradient problem during learning recurrent neural nets and problem solutions // International Journal of Uncertainty, Fuzziness and Knowledge-Based Systems, 1998. Vol. 6, No 2. pp. 107–116.
-