

МОДЕЛИРОВАНИЕ ОТКАЗОУСТОЙЧИВОСТИ ИНФОРМАЦИОННЫХ СИСТЕМ С ПРИМЕНЕНИЕМ ГРАФОВ И МАШИННОГО ОБУЧЕНИЯ

А.В. Шпинева¹, А.М. Тюнина¹

¹ФГБОУ ВО «Воронежский государственный лесотехнический университет имени Г.Ф. Морозова»

Аннотация. Данная статья предлагает подход к моделированию отказоустойчивости на основе теории графов, позволяющий формализовать топологию распределённой системы, выявлять критические узлы и каналы связи, а также оценивать структурную устойчивость сети, в сочетании с методами машинного обучения, применяемыми для прогнозирования отказов и раннего обнаружения деградации сервисов на основе эксплуатационных данных.

Ключевые слова: отказоустойчивость, распределённые системы, теория графов, машинное обучение, прогнозирование отказов, интеграция, сценарии деградации, моделирование, эксплуатационные данные, проактивное управление.

INFORMATION SYSTEM FAULT TOLERANCE MODELING USING GRAPHS AND MACHINE LEARNING

A.V. Spineva¹, A.M. Tyunina¹

¹Voronezh State University of Forestry and Technologies named after G.F. Morozov

Abstract. This article offers an approach to graph theory-based fault tolerance modeling that allows formalizing the topology of a distributed system, identifying critical nodes and communication channels, and evaluating the structural stability of the network, combined with machine learning methods used to predict failures and early detection of service degradation based on operational data.

Keywords: fault tolerance, distributed systems, graph theory, machine learning, failure prediction, integration, degradation scenarios, modeling, operational data, proactive management.

Современные распределённые системы – быстрые, но хрупкие

Современные распределённые информационные системы – например, облачные платформы и базы данных – работают шустро и эффективно. Но у них

есть слабое место: они очень чувствительны к сбоям отдельных компонентов. Отказоустойчивость – это когда система продолжает работать и держит качество, даже если какие-то её части (железо, софт или сеть) вышли из строя.

Практика показывает: отказы узлов, перегрузка каналов и постепенная деградация сервисов могут серьёзно подорвать доступность системы и нарушить согласованность данных. Старые методы повышения надёжности – типа избыточности и статического восстановления – не всегда спасают в условиях, когда топология меняется, а нагрузки непредсказуемы. Поэтому нужны более гибкие, динамичные модели.

Как помогают теория графов и машинное обучение

Теория графов позволяет представить распределённую систему в виде картинки: узлы – это вычислительные элементы или сервисы, а рёбра – связи между ними. С помощью графовых метрик можно понять, какие элементы самые уязвимые и где могут возникнуть точки отказа. Но у этого подхода есть минус – он игнорирует динамику изменений внутри системы.

Методы машинного обучения, наоборот, умеют предсказывать отказы или деградацию сервисов, анализируя данные о работе системы. Если объединить графовые модели с машинным обучением, можно построить интеллектуальные системы, которые подстраиваются под меняющиеся нагрузки и работают в условиях неопределённости.

Цель статьи – разработать такую модель отказоустойчивости, которая скрещивает теорию графов и машинное обучение. Она должна анализировать устойчивость и прогнозировать деградацию сервисов.

Почему оценка отказоустойчивости – это сложно

Оценить отказоустойчивость распределённых систем непросто. У них много уровней, компоненты сильно зависят друг от друга, а сами отказы случаются случайно. В нашем исследовании под отказоустойчивостью мы понимаем способность системы сохранять связность и работать, даже если ломаются узлы, каналы связи или сервисы.

Главная сложность – нужно учитывать и топологию сети, и динамику нагрузок, и эксплуатационные параметры. Обычные аналитические и эвристические методы здесь уже не работают.

Отдельная головная боль – предсказывать отказы узлов, глядя на структуру системы. Графовые модели описывают структуру, но статический анализ не видит, как меняются состояния узлов во времени и как накапливаются дефекты. Это снижает точность оценки отказоустойчивости.

Кроме того, важно уметь предсказывать деградацию сервисов – когда система формально работает, но её производительность или доступность уже за пределами нормы. Такие состояния часто идут впереди полных отказов. Если их вовремя заметить, можно сократить время восстановления.

Задача исследования – создать модель, которая учитывает и структуру, и динамику, используя машинное обучение для прогнозирования отказов и деградации. Это позволит перейти к проактивному управлению рисками и сделает прогнозы точнее.

Как мы ставили эксперименты

Чтобы проверить нашу методику, мы взяли и синтетические, и реальные данные. Они имитировали работу системы с большим числом узлов и сервисов. Топологию мы представили в виде взвешенного графа: вершины – узлы, рёбра – связи между ними. Это позволило анализировать устойчивость через графовые метрики – связность, центральность и так далее.

Теория графов формализует структуру, но не учитывает временную динамику и случайные отказы. Поэтому мы добавили методы машинного обучения. В исследовании использовались классификационные модели – они предсказывают отказы на основе графовых признаков и временных рядов эксплуатационных метрик. Обученные модели прогнозируют не только текущее состояние, но и развитие аварийных сценариев. Это позволяет управлять отказоустойчивостью на опережение: перераспределять нагрузку и включать резервы [1].

Методика оценки отказоустойчивости узлов объединяет графовый анализ и прогнозные данные. В итоге получается показатель, который учитывает и структурную важность узла, и вероятность его отказа. Это помогает точнее определять критические узлы и лучше управлять отказами в динамичной среде.

Предложенный подход уже проверили на реальных системах – базах данных и облачных платформах. Там отказоустойчивость зависит не только от резервирования, но и от того, насколько эффективно компоненты взаимодействуют друг с другом.

Что именно мы делали в экспериментах

Для экспериментов мы взяли синтетические и реальные данные, которые моделировали большую систему с множеством узлов и сервисов. Топологию задавали как взвешенный граф – он отражал особенности облачных инфраструктур и распределённых баз данных: с высоконагруженными узлами и запасными каналами. Эксплуатационные данные включали временные ряды метрик: загрузку процессора, потребление памяти, сетевые задержки, частоту ошибок. Это позволяло учитывать динамику работы системы.

Сценарии моделирования были разными:

- одиночные и групповые отказы узлов;
- деградация сервисов (задержки растут, пропускная способность падает).

Мы фиксировали изменения топологии, связности и агрегированные метрики качества обслуживания [3].

Как мы считали отказоустойчивость

Расчёт делали в два этапа.

Первый этап – статический анализ графа: вычисляли структурные характеристики узлов.

Второй этап – запускали модели машинного обучения. Они предсказывали вероятность отказов или деградации узлов на основе текущих и исторических данных.

Затем мы объединяли прогнозы с результатами графового анализа и получали итоговый показатель отказоустойчивости. Он сопоставляет структурную уязвимость узла с реальным риском отказа.




Рисунок 1 – Динамика показателей отказоустойчивости во времени

Что нам показали результаты

Результаты расчётов показали: интегрированная модель точнее находит критические элементы системы, чем методы, которые опираются только на анализ топологии. Узлы с высокой центральностью, но стабильными характеристиками, имели более низкий риск, чем узлы на периферии, у которых были признаки деградации. Это подтверждается расхождением между ранжированием узлов по структурным метрикам и по интегральному показателю отказоустойчивости. Значит, учитывать динамические данные очень важно.

Графики зависимости показателей отказоустойчивости от времени показали: снижение прогнозируемой устойчивости происходит до того, как случаются реальные отказы. Это значит, что критические состояния можно обнаружить заранее. Диаграммы распределения вероятности отказов показывают, что риски сконцентрированы в нескольких узлах – отказ именно этих узлов может вызвать каскадные сбои [2].

Анализ деградации сервисов подтвердил: методика выявляет предкритические состояния, которые традиционные методы мониторинга просто не замечают. Мы обнаружили корреляцию – чем ниже показатель отказоустойчивости, тем выше задержки. Это значит, что модель вполне подходит для проактивного управления и планирования превентивных мер.

В целом, объединение теории графов и машинного обучения даёт более точную оценку отказоустойчивости распределённых систем. Предложенный подход может стать основой для дальнейших исследований и практического внедрения.

Обсуждаем результаты

Эксперименты подтвердили высокую точность и надёжность нашей методики. Интеграция графового анализа и машинного обучения повысила точность оценки по сравнению с традиционными методами, которые полагаются только на статические метрики. Методика работает стабильно при разных параметрах системы и сценариях отказов – значит, её можно применять к разным распределённым архитектурам.

Сильная сторона подхода – его системность. Он учитывает и структурную значимость узлов, и их текущее (и прогнозируемое) состояние. Графы плюс машинное обучение помогают выявлять потенциальные точки отказа и адаптивно их предсказывать на основе реальных данных эксплуатации. Это снижает количество ложных срабатываний.

Но есть и минусы. Методика требует много вычислительных ресурсов: нужно рассчитывать графовые характеристики и периодически переобучать модели. Это может ограничить её применение в системах с жёсткими требованиями к задержкам.

Прогнозирование отказов и предкритических состояний особенно ценно для систем реального времени. Проблемы с качеством данных (пропуски, задержки) мы решали с помощью предварительной обработки. Если архитектура системы меняется, модели нужно обновлять – для этого требуется инкрементальное обучение.

Заключение

В ходе исследования мы разработали методику моделирования отказоустойчивости распределённых систем на основе интеграции теории графов и машинного обучения. Что получилось.

Графовое представление топологии помогает выявлять критические узлы и оценивать уязвимость к каскадным отказам.

Машинное обучение обеспечивает адаптивное прогнозирование отказов и деградации на основе эксплуатационных данных.

Сочетание этих двух подходов повышает точность оценки отказоустойчивости, потому что учитывает и статические, и динамические аспекты.

Практическая польза в том, что метод можно встроить в системы мониторинга и управления распределёнными средами – облачными платформами и базами данных. Он позволяет перейти от реактивного управления (реагируем на отказ) к проактивному (предотвращаем отказ, потому что рано заметили предкритическое состояние). Чтобы эффективно внедрить методику, нужно адаптировать модель под конкретную архитектуру, обеспечить высокое качество данных и использовать устойчивые алгоритмы машинного обучения.

Список литературы

1. Математическое моделирование отказоустойчивости информационных систем / А. И. Голева, Н. Р. Стороженко, В. И. Потапов, О. П. Шафеева // Вестник Новосибирского государственного университета. Серия: Информационные технологии. – 2019. – Т. 17, № 4. – С. 33-45. – DOI 10.25205/1818-7900-2019-17-4-5-33-45. – EDN POKCRJ.

2. Алмали, А. А. Л. Анализ надежности распределенных информационных систем в условиях воздействия внешних угроз: комплексный обзор литературы / А. А. Л. Алмали // Вестник современных цифровых технологий. – 2025. – № 22. – С. 45-53. – EDN SVXOSL.

3. Перцев, А. А. Моделирование нагрузки работы информационной системы / А. А. Перцев, А. Н. Подобрий, И. И. Халиков // Автоматизация процессов управления. – 2025. – № 2(80). – С. 79-89. – DOI 10.35752/1991-2927_2025_2_80_79. – EDN BHKLLKL.

References

1. Mathematical modeling of information systems fault tolerance / A. I. Goleva, N. R. Storozhenko, V. I. Potapov, O. P. Shafeeva // Bulletin of Novosibirsk State University. Series: Information Technology. – 2019. – Vol. 17, No. 4. – pp. 33-45. – DOI 10.25205/1818-7900-2019-17-4-5-33-45. – EDN POKCRJ.

2. Almali, A. A. L. Reliability analysis of distributed information systems under the influence of external threats: a comprehensive review of the literature / A. A. L. Almali // Bulletin of Modern Digital Technologies. – 2025. – No. 22. – pp. 45-53. – EDN SVXOSL.

3. Pertsev, A. A. Information system load modeling / A. A. Pertsev, A. N. Podobri, I. I. Khalikov // Automation of control processes. – 2025. – № 2(80). – Pp. 79-89. – DOI 10.35752/1991-2927_2025_2_80_79. – EDN BHKLLKL.