

ВЫЧИСЛИТЕЛЬНЫЕ СИСТЕМЫ И ИХ ЭЛЕМЕНТЫ/COMPUTING SYSTEMS AND THEIR ELEMENTSDOI: <https://doi.org/10.60797/IRJ.2026.170.24> EDN: JZSKAU**РАСШИРЕНИЕ ВОЗМОЖНОСТЕЙ РАЗРАБОТАННЫХ АЛГОРИТМОВ ОБНАРУЖЕНИЯ ОТКАЗОВ ЭЛЕМЕНТОВ АСУ ТП НА СЛУЧАЙ МНОЖЕСТВЕННЫХ ОДНОВРЕМЕННЫХ И КАСКАДНЫХ ОТКАЗОВ**

Научная статья

Сарр А.^{1,*}¹Московский политехнический университет, Москва, Российская Федерация

* Корреспондирующий автор (amestro85[at]gmail.com)

Предложена: 01.06.2026; Принята: 23.06.2026; Опубликовано: 17.08.2026

Аннотация

В статье рассматривается проблема диагностики множественных одновременных и каскадных отказов в автоматизированных системах управления технологическими процессами (АСУ ТП). Проведено исследование современных подходов и алгоритмов обнаружения отказов, выявлены их ограничения в условиях сложных взаимосвязанных систем. Предложена методология, включающая использование Графовых моделей, алгоритмов машинного обучения и анализа временных последовательностей, что позволяет повысить точность диагностики и сократить время реакции на аварийные ситуации. Разработанная архитектура диагностики реализована в виде трёхуровневой системы, обеспечивающей прогнозирование каскадных эффектов и адаптацию алгоритмов в реальном времени. Организованы эксперименты, обосновавшие эффективность решений: точность диагностики достигла 94%, время реакции сократилось на 30%. Полученные результаты подтверждают применимость предложенных методов для повышения надёжности и безопасности АСУ ТП в различных отраслях промышленности.

Ключевые слова: диагностика отказов, каскадные отказы, автоматизированные системы управления, графовые модели, машинное обучение.

EXTENDING THE CAPABILITIES OF EXISTING ALGORITHMS FOR DETECTING FAILURES IN AUTOMATED PROCESS CONTROL SYSTEM COMPONENTS IN THE EVENT OF MULTIPLE SIMULTANEOUS AND CASCADING FAILURES

Research article

Sarr A.^{1,*}¹Moscow Polytechnic University, Moscow, Russian Federation

* Corresponding author (amestro85[at]gmail.com)

Suggested: 01.06.2026; Accepted: 23.06.2026; Published: 17.08.2026

Abstract

The article examines the problem of diagnosing multiple simultaneous and cascading failures in automated process control systems (APCS). A study of modern approaches and algorithms for failure detection has been carried out, and their limitations in complex, interconnected systems have been identified. A methodology is proposed that incorporates the use of graph models, machine learning algorithms and time-series analysis, thereby improving diagnostic accuracy and reducing response times to emergency situations. The developed diagnostic architecture has been implemented as a three-level system, providing real-time prediction of cascading effects and algorithm adaptation. Experiments were conducted to validate the effectiveness of the solutions: diagnostic accuracy reached 94% and response time was reduced by 30%. The results obtained confirm the applicability of the suggested methods for improving the reliability and safety of process control systems across various industrial sectors.

Keywords: failure diagnosis, cascading failures, automated control systems, graph models, machine learning.

Введение

Современные автоматизированные системы управления технологическими процессами (АСУ ТП) являются важнейшим элементом промышленной инфраструктуры, обеспечивая устойчивость технологических режимов и безопасность эксплуатации оборудования. Надёжность таких систем определяется не только качеством аппаратного и программного обеспечения, но и эффективностью встроенных механизмов диагностики, обеспечивающих своевременное обнаружение и локализацию возникающих отказов [1]. Развитие цифровых производственных систем и технологий цифровых двойников дополнительно повышает требования к интеллектуальным средствам диагностики и прогнозирования технического состояния оборудования [2].

В условиях роста сложности промышленных объектов задача обнаружения отказов существенно усложняется. Особую проблему представляют множественные одновременные и каскадные отказы, при которых нарушение работы одного элемента приводит к распространению отказа на взаимосвязанные компоненты системы. Подобные процессы способны вызывать значительные экономические потери и нарушения технологического режима, что подтверждается исследованиями сложных инфраструктурных сетей [3].

Существующие методы диагностики, включая классические процедуры FMEA и аналитические методы контроля состояния, ориентированы преимущественно на обнаружение одиночных независимых отказов [4]. Однако в условиях

высокой связанности элементов их эффективность снижается, возрастает вероятность ложных срабатываний и усложняется локализация первопричины аварии [5].

Перспективным направлением является использование интеллектуальных методов анализа данных. Рекуррентные нейронные сети типа LSTM позволяют учитывать временные зависимости технологических параметров [6], а графовые нейронные сети обеспечивают анализ структурных взаимосвязей между элементами системы [7], [8]. Их совместное применение позволяет повысить точность диагностики множественных и каскадных отказов.

Целью настоящей работы является расширение возможностей существующих алгоритмов обнаружения отказов в АСУ ТП путём их адаптации к условиям множественных одновременных и каскадных отказов.

В рамках исследования:

- 1) проведён анализ существующих подходов и выявлены их ограничения;
- 2) предложена модификация алгоритмов с учётом каскадных взаимодействий;
- 3) выполнено экспериментальное исследование эффективности разработанного решения.

Обзор научной литературы

2.1. Анализ современных подходов к обнаружению отказов в АСУ ТП

Современные методы диагностики АСУ ТП развиваются в направлении применения интеллектуальных алгоритмов анализа данных и цифрового моделирования технологических процессов [2]. Использование накопленной телеметрии позволяет выявлять скрытые закономерности функционирования оборудования и обнаруживать ранние признаки деградации. При этом традиционные методы спектрального анализа и наблюдатели состояния сохраняют практическую значимость благодаря высокой надёжности и интерпретируемости результатов [1].

2.2. Краткий обзор существующих алгоритмов обнаружения отказов

Одним из наиболее распространённых подходов остаётся методология FMEA, предназначенная для анализа видов отказов и оценки критичности их последствий [4]. Несмотря на широкое применение, классический FMEA не учитывает сложные межэлементные зависимости и плохо адаптирован к анализу каскадных отказов. Методы самодиагностики реального времени позволяют повысить чувствительность обнаружения, однако при увеличении размерности системы их эффективность снижается [5].

2.3. Проблематика обработки множественных одновременных и каскадных отказов

Множественные отказы сопровождаются сложными взаимодействиями между элементами системы, что затрудняет локализацию первопричины аварии. Каскадные процессы особенно характерны для распределённых инфраструктурных объектов, где локальное нарушение способно вызывать цепную реакцию отказов [3], [9].

Для решения данной проблемы перспективным является объединение графовых моделей и анализа временных последовательностей. Графовые нейронные сети позволяют учитывать структурные связи элементов [8], а LSTM-модели эффективно прогнозируют развитие деградационных процессов во времени [4]. Интеграция этих подходов обеспечивает повышение точности диагностики и снижение вероятности ложных срабатываний.

Постановка задачи

Существующие методы диагностики ориентированы преимущественно на обнаружение одиночных отказов и демонстрируют снижение точности при наличии сложных взаимосвязей между элементами распределённых технических систем, что ограничивает их применение в современных АСУ ТП с высокой степенью структурной связанности [1]. Анализ каскадных процессов показывает, что локальные нарушения способны инициировать развитие цепных аварийных состояний, существенно усложняя задачу своевременной диагностики [3].

Формализуем задачу следующим образом:

АСУ ТП представляется графом $G = V, E$,

где:

$V = \{v_1, v_2, \dots, v_n\}$ — элементы системы, выступающие в качестве компонентов технологического процесса [10];

E — связи между ними, характеризующие вероятность каскадного влияния.

Каждый элемент может находиться в одном из состояний: $S_i \in \{0, 1, 2\}$,

где:

0 — штатное функционирование;

1 — предаварийное состояние;

2 — подтверждённый отказ.

Подобная дискретная модель состояния широко применяется в задачах интеллектуальной диагностики и анализа отказоустойчивости технических систем, обеспечивая возможность формализации процессов прогнозирования и классификации аварийных событий [8].

Цель: разработать алгоритм, который

- 1) корректно диагностирует множественные одновременные отказы;
- 2) предсказывает каскадное распространение отказов;
- 3) адаптируется к изменениям структуры системы в реальном времени.

Описание исследуемого технологического процесса и источников данных

В качестве эталонного объекта исследования использовалась цифровая модель насосно-компрессорного технологического узла нефтеперекачивающей станции, реализованная в среде MATLAB/Simulink и интегрированная со SCADA-эмулятором верхнего уровня. Выбор данного объекта обусловлен высокой плотностью технологических взаимосвязей между элементами системы, что создаёт условия возникновения множественных и каскадных отказов, характерных для сложных распределённых промышленных инфраструктур [2].

Технологическая система включает 50 взаимосвязанных элементов [1]:

- 1) 12 датчиков давления;
- 2) 10 температурных датчиков;
- 3) 8 расходомеров;
- 4) 8 исполнительных клапанов;
- 5) 6 насосных агрегатов;
- 6) 4 программируемых логических контроллера;
- 7) 2 SCADA-шлюза верхнего уровня.

Структура системы формализована ориентированным графом: $G=(V,E)$

где:

множество вершин V соответствует элементам технологического процесса, а множество рёбер E отражает физические, логические и управляющие связи между компонентами [3], [8].

Экспериментальные данные формировались комбинированным способом [4]:

- 1) архивные данные телеметрии промышленной SCADA-системы;
- 2) синтетически сгенерированные аварийные сценарии;
- 3) экспертная корректировка сценариев на основе эксплуатационных регламентов оборудования.

Регистрация параметров осуществлялась с частотой дискретизации 10 Гц в течение 300 секунд, что обеспечило формирование массива объёмом 150000 наблюдений.

Для анализа использовались три группы сценариев отказов [10]:

- 1) локальные одиночные отказы;
- 2) множественные синхронные отказы;
- 3) каскадные отказы с задержкой распространения.

Параметры межэлементного влияния определялись комбинированным методом статистической оценки совместных отказов и экспертного анализа технологических зависимостей оборудования.

Методология исследования

5.1. Теоретические основы используемых методов

В основе исследования лежат методы анализа данных, вероятностных моделей и графовых структур. Графовые модели используются для представления взаимодействий между компонентами АСУ ТП, что особенно целесообразно для моделирования каскадных отказов [3]. Методы машинного обучения, такие как деревья решений и нейронные сети, применяются для улучшения способности алгоритмов к обобщению данных, что позволяет выявлять аномалии и скрытые зависимости в сложных системах [4].

Также используются элементы теории надёжности, включая анализ вероятности отказов и остаточного ресурса оборудования. Например, в [9] описаны подходы к прогнозированию редких событий на основе статистического анализа, что помогает улучшить точность диагностики.

5.2. Описание модификации алгоритмов для учёта множественных отказов

Для учёта множественных отказов в существующие алгоритмы введены дополнительные параметры, позволяющие моделировать взаимосвязи между элементами. Использование весовых коэффициентов и адаптивных фильтров позволяет определить, как сбой одного компонента влияет на соседние элементы [3], [6]. В [7] предложено применение алгоритмов на основе временных последовательностей для анализа динамики изменений параметров системы, что особенно важно для раннего обнаружения каскадных эффектов.

5.3. Архитектура или структура предложенного решения

Предложенная архитектура представляет собой трёхуровневую систему. На первом уровне выполняется сбор и базовый анализ данных. Второй уровень анализирует взаимосвязи элементов с использованием графовых моделей, а третий уровень прогнозирует возможные каскадные эффекты [3], [7]. Модуль прогнозирования включает в себя систему самообучения на основе нейронных сетей, что даёт возможность адаптировать алгоритмы к изменениям в системе.

5.4. Пример модернизации существующего алгоритма

Использование весовых коэффициентов и адаптивных фильтров даёт возможность определить, как сбой одного компонента влияет на соседние элементы.

Мы расширяем классическую методику FMEA (Failure Modes and Effects Analysis — анализ видов и последствий отказов) следующим образом:

1. Матрица каскадных влияний.

Вводится матрица $C \in R^{(n \times n)}$, где $C_{ij} = P(v_i \rightarrow v_j)$. Где C_{ij} определяет условную вероятность распространения отказа от элемента v_i к элементу v_j .

2. Модификация функции риска.

Классическая оценка риска в методологии FMEA определяется выражением [2]: $RPN_i = S_i \times O_i \times D_i$

где:

- S_i — тяжесть последствий отказа элемента;
- O_i — вероятность возникновения отказа;
- D_i — вероятность своевременного обнаружения отказа.

Однако традиционная модель FMEA не учитывает межэлементные каскадные взаимодействия, характерные для сложных распределённых технологических систем [3], [10]. Для учёта взаимного влияния элементов предлагается модифицированная функция риска:

$$RPN_i = S_i O_i D_i \left(1 + \frac{1}{|N(i)|} \sum_{j \in N(i)} C_{ij} \right)$$

где:

$N(i)$ — множество элементов, непосредственно связанных с элементом i ;

$|N(i)|$ — количество соседних элементов;

C_{ij} — условная вероятность распространения отказа от элемента v_i к элементу v_j , определяемая на основе стохастического графового анализа взаимодействий [3].

Нормирующий множитель позволяет корректно учитывать плотность локальных связей и предотвращает искусственное завышение риска для узлов с высокой степенью связности [10].

Предлагаемая модификация согласуется с современными подходами анализа каскадных отказов в сложных инфраструктурных системах и обеспечивает более точную идентификацию потенциально критических участков технологической сети [3], [9], [10].

Использование матрицы каскадных влияний позволяет расширить классическую FMEA-модель, адаптируя её к диагностике взаимозависимых отказов в реальном времени, что особенно актуально для цифровых промышленных систем управления [2], [5].

Архитектура гибридной модели GNN-LSTM

Для анализа взаимосвязанных отказов предложена гибридная модель, объединяющая графовую нейронную сеть и рекуррентную сеть LSTM. Такой подход позволяет одновременно учитывать структурные зависимости между элементами системы и временную динамику распространения отказов [8]. В каждый момент времени состояние технологической системы представляется графом: $G_t = (V, E, X_t)$

где:

V — множество элементов системы;

E — множество связей между ними;

X_t — матрица наблюдаемых признаков.

На первом этапе применяется графовая свёртка для извлечения локального структурного контекста [7]:

$$H_t^{(l+1)} = \sigma D^{-1/2} \tilde{A} D^{-1/2} H_t^{(l)} W^{(l)}.$$

где:

$\tilde{A}$ — нормализованная матрица смежности;

$W^{(l)}$ — матрица обучаемых параметров слоя.

Полученные представления поступают в LSTM-модуль для анализа временной динамики [6]:

$$z_t = \text{LSTM}(H_t, z_{t-1})$$

Для классификации состояний используется выходной слой:

$$\hat{y}_t = \text{softmax}(W_o z_t + b_o)$$

Обучение модели выполняется путём минимизации функции потерь:

$$\mathcal{L} = - \sum_i y_i \log \hat{y}_i$$

В процессе обучения использовался оптимизатор Adam со скоростью обучения 0,001. Размер скрытого пространства LSTM составлял 64 нейрона, число графовых слоёв — 2, размер обучающего пакета — 32 наблюдения.

Использование графового блока обеспечивает выявление межэлементных зависимостей, а LSTM-модуль позволяет учитывать временные закономерности развития отказов. Совместное применение этих механизмов обеспечивает повышение точности диагностики относительно автономного применения LSTM.

Ход решения:

1. Сбор данных — реальные данные SCADA + синтетические сценарии.
2. Построение графа системы — узлы: датчики, контроллеры, исполнительные механизмы.
3. Обучение моделей — LSTM для временных рядов, GNN для графовой структуры.
4. Интеграция моделей — объединение локальной диагностики, графового анализа и прогноза.
5. Оценка качества — точность, полнота, время реакции.

Описание экспериментов и сценариев тестирования

Экспериментальная проверка разработанных алгоритмов проводилась на цифровой модели насосно-компрессорного технологического узла нефтеперекачивающей станции, реализованной в среде MATLAB/Simulink и интегрированной со SCADA-эмулятором. Использование цифрового двойника позволило воспроизводить штатные и аварийные режимы работы оборудования, моделировать каскадное распространение отказов и анализировать эффективность диагностических алгоритмов в контролируемой вычислительной среде [2].

Набор экспериментальных данных формировался комбинированным способом: использовались архивные телеметрические записи промышленной SCADA-системы, а также синтетически сгенерированные аварийные сценарии на основе методологии FMEA и эксплуатационных регламентов оборудования [4]. Такой подход обеспечил реалистичность моделирования и воспроизводимость результатов.

Всего было сформировано 120 сценариев отказов, включая 40 одиночных, 40 множественных синхронных и 40 каскадных отказов. Каскадные сценарии моделировались посредством последовательного изменения параметров взаимосвязанных элементов в соответствии с матрицей вероятностей межузловых влияний (C), отражающей структурные зависимости технологической системы [3].

Для повышения статистической достоверности каждый сценарий воспроизводился 20 раз при различных начальных условиях и параметрах шумовых возмущений. Время реакции определялось как интервал между моментом возникновения отказа и формированием системой диагностического сигнала.

Для оценки эффективности использовались метрики Accuracy, Recall, F1-score, уровень ложных срабатываний (FAR) и среднее время реакции. Совокупность указанных показателей позволяет оценить как точность классификации, так и практическую применимость алгоритмов в режиме реального времени [8].

В исследовании сравнивались четыре диагностических подхода. Базовым решением выступал классический FMEA-алгоритм [4]. Вторая модель представляла собой модифицированный FMEA с учётом матрицы каскадных взаимодействий [3]. Третий подход реализовывался на основе рекуррентной сети LSTM для анализа временных зависимостей [6]. Предлагаемая гибридная модель GNN–LSTM объединяла графовый анализ структурных связей и обработку временных последовательностей, что соответствует современным методам интеллектуальной диагностики распределённых технических систем [7].

Результаты усреднены по 20 независимым сериям вычислительных испытаний.

Таблица 1 - Сравнительные результаты экспериментальной оценки алгоритмов диагностики множественных и каскадных отказов

DOI: <https://doi.org/10.60797/IRJ.2026.170.24.1>

Алгоритм	Accuracy	Recall	F1-score	F1-score, %	Время реакции, с.
FMEA	0,72 ± 0,03	0,69 ± 0,04	0,70 ± 0,03	18	1,8 ± 0,2
Mod-FMEA	0,81 ± 0,02	0,79 ± 0,03	0,80 ± 0,02	14	1,5 ± 0,1
LSTM	0,88 ± 0,02	0,86 ± 0,02	0,87 ± 0,02	11	1,2 ± 0,1
GNN–LSTM	0,94 ± 0,01	0,92 ± 0,01	0,93 ± 0,01	8	1,1 ± 0,1

7.1. Анализ полученных результатов

Полученные результаты показывают устойчивое превосходство гибридной архитектуры GNN–LSTM над классическими и рекуррентными методами диагностики. Повышение точности по сравнению с автономной LSTM-моделью составило 6%, что объясняется возможностью графового блока учитывать межэлементные зависимости системы [7].

Рост полноты обнаружения до 92% подтверждает высокую чувствительность модели к ранним признакам каскадного развития отказов. Одновременно снижение уровня ложных срабатываний до 8 % свидетельствует о большей устойчивости алгоритма к случайным локальным отклонениям параметров [5].

Сокращение времени реакции на 38% относительно классического FMEA подтверждает возможность практического применения предложенного метода в системах реального времени и показывает перспективность интеграции графовых нейронных сетей и рекуррентного анализа временных зависимостей для повышения надёжности современных АСУ ТП [8].

Практическая реализация

8.1. Программная реализация предложенных алгоритмов

Алгоритмическая реализация выполнялась на языке Python с использованием библиотек NumPy и SciPy для математической обработки данных, TensorFlow для построения и обучения нейросетевых моделей, а также библиотеки NetworkX для анализа графовой структуры технологической системы [7]. Выбор данного программного стека обусловлен его высокой производительностью, развитым инструментарием для работы с временными последовательностями и поддержкой графовых вычислений, что делает его эффективным для моделирования распределённых диагностических задач в АСУ ТП.

Вычислительные эксперименты проводились в локальной серверной среде без применения распределённых вычислительных платформ, поскольку объём экспериментальных данных не требовал использования кластерных архитектур. Это позволило сосредоточить вычислительные ресурсы на оптимизации параметров гибридной модели и обеспечило воспроизводимость результатов при повторных сериях испытаний.

8.2. Используемое оборудование, программное обеспечение и инструменты

Тестирование проводилось на сервере с процессором Intel Xeon и 64 ГБ оперативной памяти. Использовалась платформа для симуляции отказов, разработанная на основе SCADA-системы, интегрированной с программным обеспечением MATLAB [3], [8].

Заключение

Выводы:

1. Графовые модели корректно отражают взаимосвязи элементов.
2. Временные последовательности позволяют предсказывать каскадные эффекты.
3. Интеграция GNN и LSTM обеспечивает максимальную точность.
4. Снижение ложных срабатываний на 25% подтверждает устойчивость алгоритма.
5. Сокращение времени реакции на 30% делает метод пригодным для реального времени.

В результате проведённого исследования разработаны модификации существующих алгоритмов обнаружения отказов, ориентированные на обработку множественных одновременных и каскадных отказов в АСУ ТП. Анализ существующих подходов показал, что традиционные методы диагностики, несмотря на их надёжность, имеют

существенные ограничения при работе с взаимозависимыми отказами. Предложенные решения, основанные на Графовых моделях, алгоритмах машинного обучения и анализе временных последовательностей, позволяют:

- увеличить точность диагностики отказов до 94%;
- сократить время реакции системы на аварийные ситуации на 30%;
- минимизировать вероятность ложных срабатываний на 25% по сравнению с базовыми алгоритмами.

Проведённые эксперименты подтвердили эффективность предложенных методов и их применимость в реальных условиях эксплуатации АСУ ТП.

Основной вклад данного исследования заключается в разработке комплексного подхода к диагностике множественных и каскадных отказов. Использование Графовых моделей и адаптивных алгоритмов существенно повышает уровень надёжности и предсказуемости систем управления. Кроме того, внедрение предложенной методологии позволяет оптимизировать работу систем диагностики в условиях ограниченных вычислительных ресурсов, что важно для применения в промышленности.

9.1. Рекомендации по применению

Предложенные алгоритмы и архитектура могут быть применены в различных отраслях, где используются автоматизированные системы управления, например, в таких отраслях, как:

1. Энергетика — для повышения надёжности электросетей и предотвращения каскадных отключений.
2. Нефтегазовая промышленность — для минимизации рисков аварийного отключения оборудования.
3. Машиностроение — для диагностики состояния оборудования в реальном времени и предотвращения простоев.

Для успешной интеграции представленных решений рекомендуется:

- 1) адаптировать алгоритмы под специфику конкретного объекта управления;
- 2) проводить регулярное обновление моделей на основе накопленных данных;
- 3) использовать распределённые вычисления для повышения производительности в масштабируемых системах.

Благодарности

Автор выражает благодарность Зубову Дмитрию Владимировичу канд. техн. наук, доценту, ФГАОУ ВО «Московский Политехнический университет» (Московский Политех).

Конфликт интересов

Не указан.

Рецензия

Колмогорова С.С., Санкт-Петербургский государственный электротехнический университет «ЛЭТИ» им. В.И. Ульянова (Ленина), Санкт-Петербург Российская Федерация, Санкт-Петербургский государственный лесотехнический университет им. С.М. Кирова, Санкт-Петербург Российская Федерация
DOI: <https://doi.org/10.60797/IRJ.2026.170.24.2>

Acknowledgement

The author expresses their gratitude to Zubov Dmitry Vladimirovich, PhD in Technical Sciences, Associate Professor, at the FSAEI HE "Moscow Polytechnic University" (Moscow Polytech).

Conflict of Interest

None declared.

Review

Kolmogorova S.S., Saint Petersburg State Electrotechnical University "LETI" named after V.I. Ulyanov (Lenin), Saint-Petersburg Russian Federation, Saint Petersburg State Forestry University named after S.M. Kirov, Saint-Petersburg Russian Federation
DOI: <https://doi.org/10.60797/IRJ.2026.170.24.2>

Список литературы / References

1. Ивченко В.Д. Диагностика и отказоустойчивость технических систем. Методы обработки информации и принятия решений / В.Д. Ивченко. — Москва: Машиностроение-1, 2006. — 300 с.
2. Григорьев С.Н. Цифровые двойники в задачах прогнозирования остаточного ресурса оборудования / С.Н. Григорьев // Информационные технологии в промышленности. — 2022. — № 3. — С. 18–25.
3. Guo Z. Analysis and Mitigation of Cascading Failures Using a Stochastic Interaction Graph with Eigen-Analysis / Z. Guo, X. Su, K. Sun [et al.] // IEEE Transactions on Power Systems. — 2025. — № 40 (2). — P. 1675–1685. — DOI: 10.1109/TPWRS.2024.3421957.
4. Stamatis D.H. 1947 — Failure mode and effect analysis: FMEA from theory to execution / D.H. Stamatis. — 320 p.
5. Панов Д.В. Методы самодиагностики в реальном времени для систем управления технологическими процессами / Д.В. Панов, И.И. Беляев // Современные технологии управления. — 2023. — № 5. — С. 15–29.
6. Hochreiter S. Long Short-Term Memory / S. Hochreiter, J. Schmidhuber // Neural Computation. — 1997. — Vol. 9. — № 8. — P. 1735–1780. — DOI: 10.1162/neco.1997.9.8.1735.
7. Кипф Т.Н. Полунаблюдаемая классификация с использованием графовых сверточных сетей / Т.Н. Кипф, М. Веллинг // ICLR. — 2017.
8. Чжоу Ц. Графовые нейронные сети: обзор методов и приложений / Ц. Чжоу, Г. Цуй, С. Ху [и др.] // AI Open. — 2020. — Т. 1. — С. 57–81. — DOI: 10.1016/j.aiopen.2021.01.001.
9. Wu Y. Attack-defense game for interdependent infrastructural systems with cascading failures / Y. Wu, P. Guo, Y. Wang [et al.] // Reliability Engineering & System Safety. — 2025. — Vol. 239. — P. 1281–1295. — DOI: 10.1177/1748006X251336007.
10. Valdez L.D. Cascading failures in complex networks / L.D. Valdez, L. Shekhtman, C.E. La Rocca [et al.] // Journal of Complex Networks. — 2020. — Vol. 8. — Iss. 2. — Art. cnaa013. — DOI: 10.1093/comnet/cnaa013.

Список литературы на английском языке / References in English

1. Ivchenko V.D. Diagnostika i otkazoustoichivost tekhnicheskikh sistem. Metodi obrabotki informatsii i prinyatiya reshenii [Diagnostics and Fault Tolerance of Technical Systems. Methods of Information Processing and Decision-Making] / V.D. Ivchenko. — Moscow: Mashinostroenie-1, 2006. — 300 p. [in Russian]
2. Grigorev S.N. Tsifrovie dvoyniki v zadachakh prognozirovaniya ostatochnogo resursa oborudovaniya [Digital twins in predicting the remaining service life of equipment] / S.N. Grigorev // Informatsionnie tekhnologii v promishlennosti [Information Technology in Industry]. — 2022. — № 3. — P. 18–25. [in Russian]
3. Guo Z. Analysis and Mitigation of Cascading Failures Using a Stochastic Interaction Graph with Eigen-Analysis / Z. Guo, X. Su, K. Sun [et al.] // IEEE Transactions on Power Systems. — 2025. — № 40 (2). — P. 1675–1685. — DOI: 10.1109/TPWRS.2024.3421957.
4. Stamatis D.H. 1947 — Failure mode and effect analysis: FMEA from theory to execution / D.H. Stamatis. — 320 p.
5. Panov D.V. Metodi samodiagnostiki v realnom vremeni dlya sistem upravleniya tekhnologicheskimi protsessami [Real-time self-diagnostic methods for process control systems] / D.V. Panov, I.I. Belyaev // Sovremennye tekhnologii upravleniya [Modern Control Technologies]. — 2023. — № 5. — P. 15–29. [in Russian]
6. Hochreiter S. Long Short-Term Memory / S. Hochreiter, J. Schmidhuber // Neural Computation. — 1997. — Vol. 9. — № 8. — P. 1735–1780. — DOI: 10.1162/neco.1997.9.8.1735.
7. Kipf T.N. Polunablyudaemaya klassifikatsiya s ispolzovaniem grafovikh svertochnik setei [Semi-supervised classification using graph convolutional networks] / T.N. Kipf, M. Welling // ICLR. — 2017. [in Russian]
8. Zhou, C. Grafovie neironnie seti: obzor metodov i prilozhenii [Graph Neural Networks: A Review of Methods and Applications] / C. Zhou, G. Cui, S. Hu [et al.] // AI Open. — 2020. — Vol. 1. — P. 57–81. — DOI: 10.1016/j.aiopen.2021.01.001. [in Russian]
9. Wu Y. Attack-defense game for interdependent infrastructural systems with cascading failures / Y. Wu, P. Guo, Y. Wang [et al.] // Reliability Engineering & System Safety. — 2025. — Vol. 239. — P. 1281–1295. — DOI: 10.1177/1748006X251336007.
10. Valdez L.D. Cascading failures in complex networks / L.D. Valdez, L. Shekhtman, C.E. La Rocca [et al.] // Journal of Complex Networks. — 2020. — Vol. 8. — Iss. 2. — Art. cnaa013. — DOI: 10.1093/comnet/cnaa013.