

doi: 10.17586/2226-1494-2025-25-3-536-544

УДК 004.942

Комбинированный подход к детектированию неисправностей в сложных технических системах на основе модели бонд-графа

Валентин Алексеевич Дмитриев¹, Мария Яковлевна Марусина²✉

¹ Ассоциация «Цифровые технологии в промышленности», Санкт-Петербург, 191181, Российская Федерация

^{1,2} Университет ИТМО, Санкт-Петербург, 197101, Российская Федерация

¹ valentinswsu@mail.ru, <https://orcid.org/0009-0007-5568-498X>

² myamarusina@itmo.ru✉, <https://orcid.org/0000-0002-5611-8812>

Аннотация

Введение. Разработан и исследован новый подход к детектированию неисправностей для сложных технических систем, позволяющий определить и классифицировать одиночные и множественные одновременные неисправности. Решена задача надежной и своевременной идентификации как одиночных, так и множественных одновременных неисправностей в условиях ограниченного доступа к размеченным данным. Угроза безопасной работе автономной техники является типичной проблемой для полевых условий эксплуатации, в которых традиционные подходы, основанные на моделях или данных, применяемых по отдельности, оказываются неэффективными. **Метод.** В работе представлен комбинированный подход к детектированию неисправностей. Предложенное решение сочетает в себе аналитическую модель бонд-графа и сверточную нейронную сеть. Бонд-граф формирует остатки — разницу между значениями, рассчитанными по физическим законам системы, и измерениями с датчиков. Остатки анализируются сверточной нейронной сетью, которая обучается выявлять и классифицировать неисправности по их характерным особенностям. Для учета неопределенности параметров (например, сопротивления или емкости) использовано линейное дробное преобразование. Такой подход позволяет объединить априорные знания о физике системы с возможностями глубокого обучения. **Основные результаты.** Эффективность подхода оценена на симуляторе гидравлической системы управления поворотным механизмом автономной техники. В симуляцию добавлен гауссовский шум для имитации реальных условий. Эксперименты включали начальные, ступенчатые, одиночные и множественные неисправности. Тесты с разными объемами обучающих данных при выборке менее 128 образцов показали более высокую эффективность предложенного комбинированного подхода по сравнению с классическими методами машинного обучения, такими как Random Forest или K-Nearest Neighbors). Предложено решение для детектирования неисправностей в гидравлических системах управления автономной техникой. **Обсуждение.** Разработанный подход особенно эффективен при ограниченных данных, что делает его пригодным для полевых условий. Он позволяет своевременно выявлять и классифицировать неисправности (например, утечки в клапанах или сбой электромагнитных задвижек), что снижает риск отказов и обеспечивает безопасность автономной техники. Результаты могут быть адаптированы и внедрены для электрических, механических и прочих сложных технических систем.

Ключевые слова

детектирование неисправностей, бонд-граф, сверточная нейронная сеть, линейное дробное преобразование, технические системы

Ссылка для цитирования: Дмитриев В.А., Марусина М.Я. Комбинированный подход к детектированию неисправностей в сложных технических системах на основе модели бонд-графа // Научно-технический вестник информационных технологий, механики и оптики. 2025. Т. 25, № 3. С. 536–544. doi: 10.17586/2226-1494-2025-25-3-536-544

Combined approach to fault detection in complex technical systems based on bond-graph model

Valentin A. Dmitriev¹, Maria Ya. Marusina²✉

¹ Association of Digital Technologies in Industry, Saint Petersburg, 191181, Russian Federation

^{1,2} ITMO University, Saint Petersburg, 197101, Russian Federation

¹ valentinswsu@mail.ru, <https://orcid.org/0009-0007-5568-498X>

² myamarusina@itmo.ru✉, <https://orcid.org/0000-0002-5611-8812>

Abstract

A new fault detection approach for complex technical systems has been developed and investigated, enabling the identification and classification of single and multiple simultaneous faults. The challenge of reliable and timely identification of both single and multiple simultaneous faults under conditions of limited access to labeled data has been addressed. A threat to the safe operation of autonomous equipment is a common challenge in the field operating conditions where traditional model-based or data-driven approaches, used individually, prove to be ineffective. This work presents a hybrid approach to fault detection. The proposed solution combines an analytical bond-graph model and a Convolutional Neural Network (CNN). The bond-graph generates residuals — the difference between values calculated based on the system physical laws and sensor measurements. The residuals are then analyzed by the CNN which is trained to detect and classify faults based on their characteristic features. Linear Fractional Transformation is employed to account for parameter uncertainties (e.g., resistance or capacitance). This approach allows combining a priori knowledge of the system physics with the capabilities of deep learning. The effectiveness of the approach was evaluated on a simulator of a hydraulic steering control system for autonomous equipment. Gaussian noise was added to the simulation to simulate real-world conditions. The experiments included incipient, abrupt, single, and multiple faults. Tests with varying amounts of training data, using sample sizes less than 128, demonstrated the higher effectiveness of the proposed hybrid approach compared to classical machine learning methods (such as Random Forest or K-Nearest Neighbors). A solution is proposed for fault detection in hydraulic control systems of autonomous equipment. The developed approach is particularly effective with limited data, making it suitable for field conditions. It allows for timely detection and classification of faults (e.g., valve leaks or solenoid valve failures), which reduces the risk of failures and ensures the safety of autonomous equipment. The results can be adapted and implemented for electrical, mechanical, and other complex technical systems.

Keywords

fault detection, bond-graph, convolutional neural network, linear fractional transformation, technical systems

For citation: Dmitriev V.A., Marusina M.Ya. Combined approach to fault detection in complex technical systems based on bond-graph model. *Scientific and Technical Journal of Information Technologies, Mechanics and Optics*, 2025, vol. 25, no. 3, pp. 536–544 (in Russian). doi: 10.17586/2226-1494-2025-25-3-536-544

Введение

Целью данной работы является создание надежного и эффективного подхода детектирования неисправностей (Fault Detection and Isolation, FDI), способного преодолеть ограничения существующих подходов для сложных технических систем управления, применяемых в автономной технике. При этом неисправностью принято считать состояние объекта, в котором хотя бы один параметр объекта не соответствует хотя бы одному из требований, установленных в документации на этот объект¹. Существующие методы детектирования, основанные на физическом моделировании [1–5], требуют точных аналитических моделей, построение которых затруднительно. Более того, они часто неспособны адекватно учитывать неопределенности параметров и внешние возмущения, приводящие к ложным срабатываниям. В свою очередь, методы, основанные на данных [6], такие как нейронные сети, требуют значительных объемов размеченных данных, что не всегда выполнимо в полевых условиях. В контексте автономной техники [7, 8], где надежность является критическим фактором, применение как физических моделей,

так и моделей, основанных на данных, в чистом виде часто оказывается недостаточным для решения задачи раннего обнаружения и классификации неисправностей [9], особенно в случаях одновременного возникновения нескольких неисправностей, или при развитии неисправности в начальной стадии. Для решения этой задачи предлагается новый комбинированный подход, который сочетает преимущества как физических методов, так и методов, основанных на данных [10–12]. Разработанный подход включает построение бонд-графа (Bond-Graph, BG) [13] системы для генерации остатков разницы ожидаемых и фактических значений в системе (далее — остатков), а также модели сверточных нейронных сетей (Convolutional Neural Network, CNN) для детектирования и классификации неисправностей. В работе дано общее описание задачи, представлена схема типового элемента гидравлической системы управления, основы построения модели BG и полная модель BG гидравлической системы управления. Показана применимость методов, основанных на модели BG (через построение таблицы аналитических избыточных отношений (Analytical Redundancy Relations, ARR), а также применимость методов, основанных на данных. Представлена схема работы сформированного комбинированного подхода (BG-CNN) к детектированию неисправностей и пример его работы. Далее проведено сравнение эффективности предложен-

¹ ГОСТ Р 27.102-2021 Надежность в технике. Надежность объекта. Термины и определения. Применяется с 01.01.2022 взамен ГОСТ 27.002-2015.

ного подхода с методом без предварительного выделения остаточных данных, а также продемонстрирована способность разработанного подхода работать как с одиночными, так и с множественными одновременными неисправностями.

Постановка задачи

Основная цель алгоритмов FDI состоит в том, чтобы обнаруживать, отслеживать и анализировать неисправности, возникающие в системе. Эти алгоритмы не только определяют наличие неисправности, но и оценивают степень ухудшения производительности системы и выявляют коренные причины возникших неисправностей. Достигается это посредством непрерывного мониторинга изменений в физических свойствах системы, которые проявляются в виде наблюдаемых явлений [14]. FDI традиционно делятся на три категории: методы, основанные на физических моделях системы; методы, использующие данные, собранные с системы; а также комбинированные и гибридные методы, сочетающие оба подхода. Далее будет дано обоснование выбора метода линейного дробного преобразования (Linear Fractional Transformation, LFT-BG) среди методов, базирующихся на физических моделях, и подхода глубокого обучения среди методов, основанных на данных. В качестве примера применения рассмотрена упрощенная схема гидравлической системы управления (рис. 1).

При моделировании BG система рассматривается как единый блок (рис. 1, *b*), состоящий из инерционного элемента (I), диссипативного элемента (R) и емкостного элемента (C). Входные данные внешних для системы источников могут выражаться как элементы источника усилия (S_e), а в текущем случае — источника потока (S_f). Для многопортовых элементов применяются блоки трансформатора (TF), связывающего величины одного и того же типа с входом и выходом, а именно преобразует поток в поток и усилие в усилие, а в приведенном примере использовался гиратор в модульном исполнении (MGY), связывающего поток с одной стороны с усилием с другой [14]. Модульность гиратора указывает на изменяемое значение его коэффициента. Система ограничений и связей представляется в виде 0 и 1, где узел типа 0 показывает общее усилие и, как следствие, только одну входящую причинную связь, а узел типа 1 — напротив, общий поток

и одну выходящую причинную связь. При этом усилия на каждой связи, действующей на 0-переход, равны, а потоки на данных связях в сумме равны 0. Связи на 1-переходе имеют противоположные взаимосвязи потоков и усилий, усилия в этом случае в сумме равны 0, а потоки, равны между собой. Также стоит отметить, что символы 0 и 1 выбраны как нейтральные по отношению к физической области модели. Также связи дополнительно пронумерованы от «2» до «9», начиная с источника потока, заканчивая связью «9» на диссипативном элементе рассеивания энергии в накопителе (R_u). Зная данные равенства потоков и усилий, возможно сформировать модель BG (рис. 1, *b*) гидравлической системы, представленной на рис. 1, *a*.

На рис. 1, *a* переменные представлены следующими обозначениями: p_A — исходное давления на начальном участке гидравлической системы (условной точке «А»); T — крутящий момент двигателя, а ω — угловая скорость; условное обозначение « w » представляет массовый расход компрессора, w_1 — на входе и w_2 — на выходе компрессора соответственно, индексы давления аналогичны — p_1 и p_2 ; p_c — повышающее давление в компрессоре, а p_d — результирующее давление на выходе из компрессора; p_p — давление в накопителе, V_p — объем накопителя; p_B — выходное давление элемента гидравлической системы управления.

В подходах, основанных на физике, существует различие между количественными и качественными методами, основанное на объеме априорных знаний, доступных о системе. Качественные методы используют внутреннюю структуру модели системы, причинно-следственные связи и отношения, основанные на правилах, для формулирования диагностических выводов. Эти выводы затем используются для передачи информации, связанной с неисправностями, потенциальным кандидатам на диагностику. Качественные методы анализа систем часто основываются на графических представлениях, таких как диаграммы (с ребрами, представляющими причинные связи), двудольные графы и графы связей [2]. Структура этих графовых моделей является гибкой и допускает описание различных типов взаимосвязей. Свойства графа, в частности связность, могут быть использованы для определения отслеживаемости, то есть возможности мониторинга отдельных частей системы. Также формальные определения структурной наблюдаемости и управляемости системы могут




Рис. 1. Схема элемента гидравлической системы управления: функциональная схема (*a*); соответствующая модель бонд-графа (*b*)

Fig. 1. Schematic diagram of the hydraulic control system element: functional diagram (*a*); corresponding bond-graph model (*b*)

быть сформулированы на основе анализа графа. Тем не менее, ключевым ограничением этих методов является их качественный характер, что затрудняет их применение для идентификации и классификации разнообразных неисправностей. В отличие от качественных методов, количественные методы предлагают более точные способы обнаружения неисправностей. Эти методы используют математические модели, описывающие систему через отношения между входами и выходами, и включают в себя такие методы, как наблюдатели, анализ пространства четности и оценка параметров. Рассмотрим каждый из этих методов.

Метод наблюдателей предусматривает сравнение результатов измерений процесса с их оценками, полученными на основе модели системы, для формирования остатка [3]. С целью повышения робастности к шуму и неопределенности используются множественные наблюдатели, чувствительные к различным типам неисправностей [4]. При этом методы, основанные на наблюдателях, сталкиваются со сложностями в определении местоположения неисправности в рамках модели, а также не всегда обеспечивают сходимость для нелинейных процессов. Метод оценки параметров основывается на использовании методов системной идентификации для вычисления параметров модели на основе измеренных входных и выходных данных. Далее полученные параметры сравниваются с эталонными значениями, что позволяет обнаруживать неисправности. Недостатком подхода является зависимость от постоянного изменения входных данных системы, что может создавать проблемы при анализе стационарных процессов.

Проанализировав существующие методы FDI, основанные на физике, можно сделать вывод о том, что BG является заслуживающим внимания вариантом из-за присущих ему преимуществ, вытекающих как из качественных, так и из количественных аспектов. Взаимодействие между узлами в BG описывается с использованием двух обобщенных переменных: усилие — $e(t)$ (в физических понятиях это может быть — сила, напряжение, давление) и поток — $f(t)$ (скорость, ток, расход) [15]. На рис. 2 показано определение направления мощности для элемента А, посылающего энергию на В, и связанного с этим усилия, показанного над полустрелкой, а также потока — по определению, под полустрелкой. Такое обозначение принято называть «связь». При этом причинно-следственную связь усилия и потока графически обозначают вертикальной чертой. Если черта находится перед полустрелкой (связи 2, 5, 6, 8 и 9, рис. 1, б), то мощность направлена от потока к усилию, а в случае расположения после полустрелки — от усилия к потоку.

Применение методов, основанных на физической модели системы

Модель BG формируется с помощью физических законов, описывающих динамику гидравлической системы управления, а также на основе понимания взаимосвязей между компонентами системы (рис. 1, б). Добавляя к модели элементы неисправностей, как




Рис. 2. Направление мощности бонд-графа и связанные с ним определения усилия и потока: элемент «В» получает энергию от «А»

Fig. 2. Bond-graph power direction and associated definitions of force and flow: element “B” receives power from “A”

например элемент Ru, отражающий сопротивление дросселя (связь 9, рис. 1, б), можно создать диагностическую модель бонд-графа (Diagnostics Bond-Graph, DBG). DBG позволяет использовать количественные FDI путем создания аналитических избыточных отношений (ARR) за счет использования подхода, основанного на анализе причинно-следственного пути [2]. ARR — математические выражения, которые связывают измеряемые значения с ожидаемыми, рассчитанными на основе модели.

ARR могут быть записаны в терминах только известных для системы значений

$$ARR = \{U, S, \vartheta\},$$

где U — набор входных данных для системы (известный); S — измерения датчика (известные); ϑ — набор значений параметров (известный). Для реализации ARR были выполнены следующие этапы: создана модель BG системы; преобразована DBG путем дуализации датчиков (определения местоположения датчика); выведены ARR, исключая неизвестные переменные. ARR-модель выдает числовую оценку, которая называется остаточным сигналом (r_i). Набор этих сигналов ($r = \{r_1, r_2, \dots, r_q\}$) показывает, как работает система. В идеале эти остатки близки к 0, когда система функционирует нормально, и заметно отличаются от 0 при возникновении неисправностей. Для оценки применимости подхода на основе модели BG, строится матрица сигнатур неисправностей (Fault Signature Matrices, FSM), представленная в виде таблицы. Строки FSM соответствуют компонентам системы (например, насос, клапан, датчик), а столбцы соответствуют ARR. Элементы FSM (γ_{ij}) являются булевыми переменными (0 или 1), указывающими на чувствительность соответствующего остатка ARR_j к компоненту системы E_m ($\gamma = 1$ — если ARR_j чувствителен к компоненту E_m ; $\gamma = 0$ — если не чувствителен). Сигнатура неисправности компонента E_i хранится в строке FSM. Если вектор остатков совпадает с сигнатурой компонента, то можно локализовать неисправность в этом компоненте.

Для схемы на рис. 1 исследование проводилось относительно 8-ми возможных неисправностей: давление штока; силы, действующие на поршень; сопротивление поршня; гидравлическое сопротивление накопителя; гидравлическое сопротивление клапана; сопротивление утечки и внешние силы. Результаты пространства остатков и датчиков, описанных неисправностей, представлены в разделе «Комбинированный подход».

Ключевое преимущество BG заключается в его применимости к нелинейным системам. Однако метод имеет ограничение: предполагается, что параметры

Таблица. Структурный анализ матрицы признаков неисправностей (FSM) в частном и общем видах (сокращенный пример заполнения)

Table. Structural analysis of the fault sign matrix (FSM) in private and general form

Частный вид матрицы			Общий вид матрицы			
Наименования строк	Наименования столбцов		Наименования строк	Наименования столбцов		
	ARR_1	ARR_2		ARR_1	...	ARR_j
p	1	0	E_1	γ_{11}	...	γ_{1j}
R	1	1	...	...	...	...
F	1	0	E_m	γ_{m1}	...	γ_{mj}

Примечание. p — давление штока; R — гидравлическое сопротивление; F — силы, действующие на поршень.

модели (например, сопротивление клапанов, емкость накопителя, инерция жидкости) известны точно и остаются постоянными. Однако в реальных системах эти параметры подвержены неопределенностям. Для решения этой проблемы используется метод линейного BG с дробным преобразованием (LFT-BG), где параметры моделируются с учетом неопределенностей. LFT-BG расширяет классический BG, моделируя параметры в виде:

$$\theta_i = \theta_{in}(1 + \delta_i), \delta_i \in [-\Delta, \Delta],$$

где Δ — максимальная относительная неопределенность; θ_i — параметры системы; θ_{in} — номинальное значение параметров системы; δ_i — номинальный коэффициент неопределенности системы.

Применение методов, основанных на данных

Для обработки остаточных сигналов и выявления закономерностей неисправностей были использованы CNN [16–18]. Несмотря на то, что остаточные сигналы (r_1, r_2) представляют собой временные ряды, выбор CNN обусловлен рядом факторов. Для выявления пространственных паттернов в данных остатки преобразуются в спектрограммы с использованием кратковременного преобразования Фурье. При этом преимущество CNN заключается в том, что спектрограммы имеют структуру, аналогичную изображениям, где сверточные слои эффективно выделяют локальные особенности (например, резкие изменения амплитуды, характерные для утечек). Кроме этого CNN, как архитектура глубокого обучения, обладает способностью самостоятельно извлекать признаки из данных. Однако, чтобы корректно оценить преимущества CNN перед другими, более простыми методами машинного обучения, сравнение проведено в равных условиях. Это означает, что все сравниваемые модели использовали одни и те же входные данные, а именно — остатки, сгенерированные моделью BG. Использование остатков является важным этапом предобработки, который позволяет учесть физику процесса и повысить качество детектирования. Сравнение CNN с другими моделями, примененными к «сырым» данным, было бы некорректным, поскольку CNN изначально предназначена для работы со структурированными данными, такими как изображения или — спектрограммы остатков. Основной принцип работы CNN заключается в применении операций свертки

к входным данным, где каждый слой CNN преобразует вход (X), создавая выходные признаки (Z_k).

$$Z_k = \sigma(W_k * X + B_k),$$

где «*» — оператор 2D-свертки; W_k — веса, связанные со сверточным ядром; B_k — элемент смещения; $\sigma(x)$ — функция активации: $\sigma(x) = \max(0, x)$; k — обозначение число ядер.

Для уменьшения размерности и фильтрации шума используются слои максимального пулинга (maxpooling). Данная операция выделяет наиболее значимые признаки, создавая карту признаков $Z_{k_{pooled}}$ с использованием окна $s \times s$:

$$Z_{k_{pooled}} = \text{maxpool}(Z_k);$$

$$Z_{k_{pooled}}(i, j) = \max(Z_k[i: i + s, j: j + s]).$$

Полученная карта признаков после пулинга преобразуется в одномерный вектор с помощью слоя сглаживания. Это $Z_{Flatten}$, использующийся полносвязной сетью для классификации неисправностей. Если карта признаков $Z_{k_{pooled}}$ имеет H_p столбцов и W_p строк, то вектор $Z_{Flatten}$ формируется следующим образом:

$$Z_{Flatten} = [Z_{k_{pooled}}(1, 1), Z_{k_{pooled}}(1, 2), \dots, Z_{k_{pooled}}(H_p, 1), Z_{k_{pooled}}(H_p, 2), \dots, Z_{k_{pooled}}(H_p, W_p)].$$

Затем $Z_{Flatten}$ подается на вход полносвязной сети, которая имеет M нейронов на выходном слое, где M — количество классов неисправностей. Выход сети определяется с помощью функции softmax:

$$\hat{Y} = \text{softmax}(\Phi Z_{Flatten} + \mathbf{b}),$$

$$\text{softmax}(\mathbf{x}_i) = \frac{e^{x_i}}{\sum_{j=1}^M e^{x_j}},$$

где Φ — веса; $\mathbf{b}$ — смещение полносвязной сети; e^{x_i} — экспоненциальное значение i -го элемента вектора $\mathbf{x}$, а e^{x_j} — аналогичное значение j -го элемента, используемое для нормализации. Функция softmax преобразует выходы полносвязной сети в нормализованное распределение вероятностей, облегчая интерпретацию результатов, при этом полносвязная сеть используется для классификации признаков, извлеченных сверточными слоями.

Процесс обучения CNN заключается в настройке параметров сети (весов и смещений) путем минимизации функции потерь:

$$Loss = -\frac{1}{n1} \sum_{i=1}^{n1} \sum_{j=1}^M Y_{ij} \log(\hat{Y}_{ij}),$$

где $n1$ — число обучающих выборок; Y_{ij} и $\hat{Y}_{ij}$ — целевые и предсказанные значения для i -ой выборки и j -ого класса. В этом процессе используются обучающие данные X_{train} с соответствующими метками Y_{train} . Для тестирования используются тестовые данные X_{test} . Для задачи мультиклассовой классификации применяется метрика F1-score, как наиболее сбалансированная метрика, учитывающая как точность, так и полноту.

Таким образом, для обучения CNN используется набор остаточных сигналов, которые формируются из разработанной модели BG, проходя через процедуру свертки, пулинга, и сглаживания для создания входных данных для классификатора на основе полносвязной сети. Это позволяет применить возможности глубокого обучения для эффективного обнаружения и классификации неисправностей на основе чувствительных к неисправностям остаточных сигналов.

Комбинированный подход

Как показано на рис. 3, предложенный комбинированный подход BG-CNN состоит из блока генерации остатков BG и блока классификации неисправностей на основе CNN. Чувствительные к неисправностям остатки генерируются из модели BG [19] и используются в качестве входных данных для модели CNN. Этот подход имеет две фазы: во-первых, помеченные сигналы остатков неисправностей используются для автономного обучения CNN. Во второй фазе сигналы остатков в режиме реального времени, генерируемые моделью BG, используются обученной моделью CNN для классификации типов неисправности.

Схема работы предложенного подхода состоит из трех основных этапов.

Этап 1. Строится модель гидравлической системы с использованием BG. В полученной модели учитываются

неопределенности параметров с помощью LFT-BG. Модель позволяет рассчитать *остатки* — разницу между ожидаемыми значениями, рассчитанными моделью, и измеренными значениями, полученными с датчиков. В системе генерируется два остатка: r_1 , связанный с электрической частью, и r_2 — гидравлической частью. Далее остаточные сигналы r_1 и r_2 используются для обучения CNN. Каждый остаток, представленный в виде одномерного временного ряда $X \in R^{(N \times 100 \times 2)}$, с которым потом и работает CNN. Преобразование происходит за счет предобработки данных с целью устранения несоответствия в масштабах сигналов от датчиков и актуаторов, а также минимизации влияния шумов на работу модели.

Этап 2. Проводится предобработка в три шага: нормализация данных, фильтрация шумов, а также сегментация временных рядов. Нормализация данных представлена следующим решением:

$$X_{norm} = \frac{X - \mu}{\sigma},$$

где μ — среднее значение параметра; σ — стандартное отклонение по обучающей выборке. Фильтрация шумов выполняется посредством применения фильтра Калмана, а сегментация временных рядов происходит в два этапа: для начала сигналы разбиваются на окна длиной 100 отсчетов, что соответствует 100 мс при выбранной частоте дискретизации в 1 кГц, далее сформированные окна перекрываются на 50 %, что позволяет увеличить размер обучающей выборки. Длительность измерений и интервал дискретизации выбраны на основе анализа спектральной плотности мощности для сигналов датчиков и остатков. Выбранные значения обеспечивают достаточное разрешение для обнаружения характерных частот, связанных с неисправностями, и при этом не приводят к избыточному объему данных.

В процессе обучения CNN изучает взаимосвязь между этими остаточными сигналами и различными типами неисправностей (включая их одиночные и множественные проявления). В рассмотренном случае количество классов неисправностей для одиночных проявлений равно 6, и для множественных — 8. После




Рис. 3. Структурная схема комбинированного подхода

Fig. 3. Structure diagram of the combined approach

обучения CNN может использоваться в режиме реального времени.

Этап 3. Выполняется обнаружение ошибки. Когда новые данные поступают от датчиков, модель BG генерирует остаточные сигналы, которые передаются обученной CNN, и она определяет, присутствует ли какая-либо неисправность, и если да, то какая.

Таким образом, предложенный подход сочетает в себе преимущества использования физической модели для получения устойчивых к шумам остатков и возможности машинного обучения для извлечения скрытых закономерностей и классификации сложных нелинейностей в данных, что позволяет добиться лучшей точности и надежности детектирования неисправностей в гидравлических системах. Для сравнения на двух диаграммах (рис. 4) представлены результаты подхода FDI на остаточных данных и на данных с датчиков, где наглядно видно, что с применением сформированного подхода детектирование неисправностей существенно упрощается. На рис. 4, *a* ось « ARR_1 » представляет значения параметров в приведенном масштабе, а ось « ARR_2 » — значения пространства остатков, на рис. 4, *b* представлены нормализованные данные пространства датчиков относительно времени. Рассматривался следующий список параметров неисправностей: Healthy — случайный набор проверочных данных, параметры остатков которых приближены к 0; I/W — силы, действующие на поршень; I — внешние силы; K — сопротивление утечки; Re/Rm — результирующее сопротивление; Re — гидравлическое сопротивление накопителя; Rm — гидравлическое сопротивление клапана; W — сопротивление поршня.

Обсуждение

Для оценки эффективности предложенного комбинированного подхода, было проведено его сравнение с методами, основанными только на BG или только на CNN, а также с традиционными методами машинного обучения (ML), такими как Random Forest (RF),

K-Nearest Neighbors (KNN), Artificial Neural Networks (ANN) и метод опорных векторов (Support Vector Machines или просто SVM). Важно отметить, что все сравниваемые методы, включая RF, KNN, ANN и SVM, использовали в качестве входных данных те же остатки, сгенерированные моделью BG, что и предложенный подход (BG-CNN). Это обеспечивает честное и объективное сравнение, поскольку все модели работают с одинаковой предобработанной информацией, учитывая физику системы. Проведена оптимизация гиперпараметров как предложенного подхода, так и методов для сравнения. Использовался метод случайного поиска (Random Search). Оптимизировались следующие гиперпараметры: для CNN — количество сверточных слоев, количество фильтров в каждом слое, размер ядра свертки, функция активации, метод пулинга, learning rate; для RF — количество деревьев, максимальная глубина дерева, количество признаков для разделения; для KNN — количество соседей; для ANN — количество скрытых слоев, количество нейронов в каждом слое, функция активации, learning rate. Результаты сравнительного анализа, полученные на едином наборе данных в 2384 образца, объединяющем все типы неисправностей (начальные, ступенчатые, одиночные и множественные одновременные), показали явное превосходство предложенного подхода над всеми остальными методами, особенно при малом количестве обучающих данных. Результаты представлены на рис. 5.

При увеличении размера обучающей выборки эффективность CNN, RF и KNN приближается к комбинированному подходу, но достигает близких значений лишь при выборке выше 128. Важно отметить, что разработанный подход BG-CNN показал наилучшую способность обнаруживать начальные неисправности на ранних этапах, а также изолировать множественные одновременные неисправности, которые представляют наибольшую сложность для традиционных методов FDI. Была проведена оценка влияния различных параметров модели на производительность, включая размер




Рис. 4. Результаты детектирования неисправностей гидравлической системы: на основе остаточных данных (*a*); на основе данных датчиков (*b*)

Fig. 4. Results of hydraulic system fault detection: based on residual data (*a*); based on sensor data (*b*)




Рис. 5. Сравнение эффективности методов детектирования неисправностей

Fig. 5. Comparison of the fault detection methods effectiveness

обучающей выборки. Результаты показали, что подход BG-CNN сохраняет точность, превышающую точность CNN, RF и KNN, как отдельных методов, не менее, чем на 10 % при различных значениях параметров и количестве измерений, большем, чем 128. Проведено исследование чувствительности модели к параметрическим неопределенностям, что показало следующее:

- модель с LFT-BG демонстрирует бльшую точность по сравнению с подходом с константными значениями;
- результаты не зависят от размера обучающей выборки, но наибольший прирост заметен при размере выборки 32;
- подход BG-CNN показывает лучшие результаты в обнаружении неисправностей на ранних этапах.

Литература

1. Bouamama B.O., Biswas G., Loureiro R., Merzouki R. Graphical methods for diagnosis of dynamic systems: Review // *Annual reviews in control*. 2014. V. 38. N 2. P. 199–219. <https://doi.org/10.1016/j.arcontrol.2014.09.004>
2. Isermann R. *Fault-Diagnosis Applications: Model-Based Condition Monitoring: Actuators, Drives, Machinery, Plants, Sensors, and Fault-Tolerant Systems*. Springer Science & Business Media, 2011. 354 p.
3. Chen J., Patton R.J. *Robust Model-Based Fault Diagnosis for Dynamic Systems*. Springer Science & Business Media, 2012. V. 3. 356 p.
4. Ding S.X. *Model-Based Fault Diagnosis Techniques: Design Schemes, Algorithms and Tools*. Springer Science & Business Media, 2012. 504 p.
5. Akhenak A., Duviella E., Bako L., Lecoeuche S. Online fault diagnosis using recursive subspace identification: application to a dam-gallery open channel system // *Control Engineering Practice*. 2013. V. 21. N 6. P. 797–806. <https://doi.org/10.1016/j.conengprac.2013.02.013>
6. Lei Y., Yang B., Jiang X., Jia F., Li N., Nandi A.K. Applications of machine learning to machine fault diagnosis: a review and roadmap // *Mechanical Systems and Signal Processing*. 2020. V. 138. P. 106587. <https://doi.org/10.1016/j.ymssp.2019.106587>
7. Xu G., Yu Z., Lu N., Lv G. High-gain observer-based sliding mode control for hydraulic excavators // *Journal of Harbin Engineering University*. 2021. V. 42. N 6. P. 885–892.
8. Shen W., Yuan X., Liu M. Event-triggered control for hydraulic position tracking system with extended state observer // *Journal of Mechanical Engineering*. 2022. V. 58. N 8. P. 274–284. <https://doi.org/10.3901/JME.2022.08.274>
9. Nasiri S., Khosravani M.R., Weinberg K. Fracture mechanics and mechanical fault detection by artificial intelligence methods: a review // *Engineering Failure Analysis*. 2017. V. 81. P. 270–293. <https://doi.org/10.1016/j.engfailanal.2017.07.011>

Заключение

Разработан комбинированный подход детектирования неисправностей (FDI) для гидравлических систем управления, интегрирующий графы связей (BG) с линейным дробным преобразованием (LFT-BG) для генерации устойчивых остатков, и сверточные нейронные сети (CNN) для их классификации. Подход BG с LFT-BG позволил создать аналитическую модель и сгенерировать остатки, чувствительные к неисправностям, а CNN, в свою очередь, эффективно выявила закономерности для классификации разных типов неисправностей, включая их начальные, ступенчатые и множественные проявления. Предложенный комбинированный подход BG-CNN продемонстрировал превосходство над другими распространенными методами машинного обучения, примененными к тем же остаточным данным, особенно в условиях ограниченных обучающих данных, обеспечивая более высокую точность детектирования неисправностей, а также более высокую скорость обучения. Эксперименты показали, что подход LFT-BG с CNN эффективно обрабатывает нелинейности и позволяет создавать устойчивую к шуму систему детектирования. Практическая значимость заключается в повышении надежности автономной техники, где точное детектирование неисправностей гидравлических систем критично. Дальнейшие исследования должны быть направлены на адаптацию подхода к другим системам, оптимизацию архитектуры CNN и обучение на малых выборках, а также на изучение влияния параметров модели и применение подхода к реальным промышленным системам.

References

1. Bouamama B.O., Biswas G., Loureiro R., Merzouki R. Graphical methods for diagnosis of dynamic systems: Review. *Annual reviews in control*, 2014, vol. 38, no. 2, pp. 199–219. <https://doi.org/10.1016/j.arcontrol.2014.09.004>
2. Isermann R. *Fault-Diagnosis Applications: Model-Based Condition Monitoring: Actuators, Drives, Machinery, Plants, Sensors, and Fault-Tolerant Systems*. Springer Science & Business Media, 2011, 354 p.
3. Chen J., Patton R.J. *Robust Model-Based Fault Diagnosis for Dynamic Systems*. Springer Science & Business Media, 2012, vol. 3, 356 p.
4. Ding S.X. *Model-Based Fault Diagnosis Techniques: Design Schemes, Algorithms and Tools*. Springer Science & Business Media, 2012. 504 p.
5. Akhenak A., Duviella E., Bako L., Lecoeuche S. Online fault diagnosis using recursive subspace identification: application to a dam-gallery open channel system. *Control Engineering Practice*, 2013, vol. 21, no. 6, pp. 797–806. <https://doi.org/10.1016/j.conengprac.2013.02.013>
6. Lei Y., Yang B., Jiang X., Jia F., Li N., Nandi A.K. Applications of machine learning to machine fault diagnosis: a review and roadmap. *Mechanical Systems and Signal Processing*, 2020, vol. 138, pp. 106587. <https://doi.org/10.1016/j.ymssp.2019.106587>
7. Xu G., Yu Z., Lu N., Lv G. High-gain observer-based sliding mode control for hydraulic excavators. *Journal of Harbin Engineering University*, 2021, vol. 42, no. 6, pp. 885–892.
8. Shen W., Yuan X., Liu M. Event-triggered control for hydraulic position tracking system with extended state observer. *Journal of Mechanical Engineering*. 2022, vol. 58, no. 8, pp. 274–284. (in Chinese). <https://doi.org/10.3901/JME.2022.08.274>
9. Nasiri S., Khosravani M.R., Weinberg K. Fracture mechanics and mechanical fault detection by artificial intelligence methods: a review. *Engineering Failure Analysis*, 2017, vol. 81, pp. 270–293. <https://doi.org/10.1016/j.engfailanal.2017.07.011>

10. Hu Z., Zhao G., Li F., Zhou D. Fault diagnosis for nonlinear dynamical system based on adaptive unknown input observer // *Control and Decisions*. 2016. V. 31. N 5. P. 901–906.
11. Liu Y., Sun C., Chen Y., Lin G. Design and application on sliding mode controller for roller microporous system based on disturbance observer // *Forging and Stamping Technology*. 2022. V. 47. N 3. P. 116–120.
12. Bohagen B., Gravdahl J.T. Active surge control of compression system using drive torque // *Automatica*. 2008. V. 44. N 4. P. 1135–1140. <https://doi.org/10.1016/j.automatica.2007.11.002>
13. Дмитриев В.А., Марусина М.Я. Особенности построения бонд-графа шагающих роботов // *Известия высших учебных заведений. Приборостроение*. 2024. Т. 67. № 2. С. 195–199. <https://doi.org/10.17586/0021-3454-2024-67-2-195-199>
14. Rahman A., Hasan N., Zaki M. Modelling and validation of electric vehicle drive line architecture using Bond Graph // *Test Engineering and Management*. 2020. V. 82. P. 15154–15167.
15. Gonzalez-Avalos G., Gallegos N.B., Ayala-Jaimes G., Garcia A.P. Modeling and simulation in Multibond Graphs applied to three-phase electrical systems // *Applied Sciences*. 2023. V. 13. N 10. P. 5880. <https://doi.org/10.3390/app13105880>
16. Li F., Wu Z., Li J., Lai Z., Zhao B., Min C. A multi-step CNN-based estimation of aircraft landing gear angles // *Sensors*. 2021. V. 21. N 24. P. 8440. <https://doi.org/10.3390/s21248440>
17. Chen J., Xu Q., Guo Y., Chen R. Aircraft landing gear retraction/extension system fault diagnosis with 1-D dilated convolutional neural network // *Sensors*. 2022. V. 22. N 4. P. 1367. <https://doi.org/10.3390/s22041367>
18. Saucedo-Dorantes J.J., Delgado-Prieto M., Osornio-Rios R.A., Romero-Troncoso R.J. Industrial data-driven monitoring based on incremental learning applied to the detection of novel faults // *IEEE Transactions on Industrial Informatics*. 2020. V. 16. N 9. P. 5985–5995. <https://doi.org/10.1109/TII.2020.2973731>
19. Mo H., Li Y. Fault diagnosis based on interval analytic redundancy relation // *Journal of Nanjing University of Aeronautics and Astronautics*. 2021. V. 53. N 6. P. 972–980.
10. Hu Z., Zhao G., Li F., Zhou D. Fault diagnosis for nonlinear dynamical system based on adaptive unknown input observer. *Control and Decisions*, 2016, vol. 31, no. 5, pp. 901–906.
11. Liu Y., Sun C., Chen Y., Lin G. Design and application on sliding mode controller for roller microporous system based on disturbance observer. *Forging and Stamping Technology*, 2022, vol. 47, no. 3, pp. 116–120. (in Chinese)
12. Bohagen B., Gravdahl J.T. Active surge control of compression system using drive torque. *Automatica*, 2008, vol. 44, no. 4, pp. 1135–1140. <https://doi.org/10.1016/j.automatica.2007.11.002>
13. Dmitriev V.A., Marusina M.Ya. Features of constructing a bond graph of walking robots. *Journal of Instrument Engineering*, 2024, vol. 67, no. 2, pp. 195–199. (in Russian). <https://doi.org/10.17586/0021-3454-2024-67-2-195-199>
14. Rahman A., Hasan N., Zaki M. Modelling and validation of electric vehicle drive line architecture using Bond Graph. *Test Engineering and Management*, 2020, vol. 82, pp. 15154–15167.
15. Gonzalez-Avalos G., Gallegos N.B., Ayala-Jaimes G., Garcia A.P. Modeling and simulation in Multibond Graphs applied to three-phase electrical systems. *Applied Sciences*, 2023, vol. 13, no. 10, pp. 5880. <https://doi.org/10.3390/app13105880>
16. Li F., Wu Z., Li J., Lai Z., Zhao B., Min C. A multi-step CNN-based estimation of aircraft landing gear angles. *Sensors*, 2021, vol. 21, no. 24, pp. 8440. <https://doi.org/10.3390/s21248440>
17. Chen J., Xu Q., Guo Y., Chen R. Aircraft landing gear retraction/extension system fault diagnosis with 1-D dilated convolutional neural network. *Sensors*, 2022, vol. 22, no. 4, pp. 1367. <https://doi.org/10.3390/s22041367>
18. Saucedo-Dorantes J.J., Delgado-Prieto M., Osornio-Rios R.A., Romero-Troncoso R.J. Industrial data-driven monitoring based on incremental learning applied to the detection of novel faults. *IEEE Transactions on Industrial Informatics*, 2020, vol. 16, no. 9, pp. 5985–5995. <https://doi.org/10.1109/TII.2020.2973731>
19. Mo H., Li Y. Fault diagnosis based on interval analytic redundancy relation. *Journal of Nanjing University of Aeronautics and Astronautics*, 2021, vol. 53, no. 6, pp. 972–980.

Авторы

Дмитриев Валентин Алексеевич — руководитель практики, Ассоциация «Цифровые технологии в промышленности», Санкт-Петербург, 191181, Российская Федерация; аспирант, Университет ИТМО, Санкт-Петербург, 197101, Российская Федерация, <https://orcid.org/0009-0007-5568-498X>, valentinswsu@mail.ru

Марусина Мария Яковлевна — доктор технических наук, профессор, профессор, Университет ИТМО, Санкт-Петербург, 197101, Российская Федерация, <https://orcid.org/0000-0002-5611-8812>, myamarusina@itmo.ru

Authors

Valentin A. Dmitriev — Head of the Practice, Association of Digital Technologies in Industry, Saint Petersburg, 191181, Russian Federation; PhD Student, ITMO University, Saint Petersburg, 197101, Russian Federation, <https://orcid.org/0009-0007-5568-498X>, valentinswsu@mail.ru

Maria Ya. Marusina — D.Sc., Full Professor, ITMO University, Saint Petersburg, 197101, Russian Federation, <https://orcid.org/0000-0002-5611-8812>, myamarusina@itmo.ru

Статья поступила в редакцию 05.02.2025

Одобрена после рецензирования 02.04.2025

Принята к печати 22.05.2025

Received 05.02.2025

Approved after reviewing 02.04.2025

Accepted 22.05.2025



Работа доступна по лицензии
Creative Commons
«Attribution-NonCommercial»