

УДК 004.89

Ермоленко Юрий Александрович, аспирант кафедры ЭВМ, Рязанский государственный радиотехнический университет имени В. Ф. Уткина, Россия,
г. Рязань

Научный руководитель: Мельник Ольга Владимировна, доктор технических наук, доцент, Рязанский государственный радиотехнический университет имени В. Ф. Уткина, Россия, город Рязань

ПРИМЕНЕНИЕ ГРАФОВЫХ НЕЙРОННЫХ СЕТЕЙ ДЛЯ ПРОГНОЗИРОВАНИЯ ОТКАЗОВ В СЛОЖНЫХ ИНЖЕНЕРНЫХ СИСТЕМАХ

Аннотация

В статье рассматривается задача прогнозирования отказов в сложных инженерных системах, агрегаты которых связаны физическими и функциональными зависимостями. Показано, что традиционные модели на основе временных рядов не учитывают топологию системы и потому ограниченно отражают распространение деградации между связанными узлами. Цель исследования — оценить эффективность графовых нейронных сетей при прогнозировании отказов по сравнению с последовательностными архитектурами. Предложена пространственно-временная графовая модель, в которой узлы графа соответствуют агрегатам, рёбра — связям между ними, а признаки узлов формируются из показаний датчиков в скользящем окне. Проведён вычислительный эксперимент на корпусе из 1200 траекторий эксплуатации, сопоставлены шесть моделей по метрикам F1, PR-AUC и среднему упреждению прогноза. Установлено, что предложенная модель повышает F1-меру с 0,79 до 0,88 и обеспечивает раннее обнаружение предотказного состояния в среднем на 14 % раньше базовых моделей.

Полученные результаты подтверждают целесообразность учёта топологии системы при построении систем предиктивного обслуживания.

Annotation

The paper addresses the problem of failure prediction in complex engineering systems whose components are connected by physical and functional dependencies. It is shown that conventional time-series models ignore the system topology and therefore poorly reflect the propagation of degradation between connected nodes. The aim of the study is to assess the efficiency of graph neural networks for failure prediction in comparison with sequence-based architectures. A spatio-temporal graph model is proposed, in which graph nodes correspond to components, edges correspond to the links between them, and node features are formed from sensor readings within a sliding window. A computational experiment was carried out on a corpus of 1200 operational trajectories; six models were compared in terms of F1, PR-AUC and the average prediction lead time. It is found that the proposed model raises the F1-score from 0.79 to 0.88 and provides early detection of the pre-failure state on average 14 % earlier than the baseline models. The obtained results confirm the expediency of taking the system topology into account when building predictive-maintenance systems.

Ключевые слова: информационные технологии, искусственный интеллект, графовые нейронные сети, прогнозирование отказов, предиктивное обслуживание, сложные инженерные системы, остаточный ресурс.

Keywords: information technologies, artificial intelligence, graph neural networks, failure prediction, predictive maintenance, complex engineering systems, remaining useful life.

Введение

Современные сложные инженерные системы — энергетические установки, технологические линии, транспортные комплексы — представляют собой совокупность взаимосвязанных агрегатов, отказ одного из которых способен каскадно распространяться по системе. Своевременное прогнозирование отказов является ключевым элементом стратегии предиктивного обслуживания, позволяющей снизить аварийность и эксплуатационные издержки. Накопление больших объёмов эксплуатационной телеметрии создало предпосылки для применения методов машинного обучения к этой задаче.

Преобладающим подходом к прогнозированию отказов остаётся анализ многомерных временных рядов с помощью рекуррентных (LSTM, GRU), свёрточных (TCN) и трансформерных архитектур. Однако все они рассматривают сигналы датчиков как независимые либо плоско объединённые каналы и не учитывают структуру связей между агрегатами. Между тем именно топология системы во многом определяет характер распространения деградации: ухудшение состояния одного узла повышает нагрузку на смежные. Это обуславливает актуальность применения графовых нейронных сетей (Graph Neural Networks, GNN), для которых структура связей является естественным входным представлением.

Цель исследования — оценить эффективность графовых нейронных сетей при прогнозировании отказов в сложных инженерных системах по сравнению с последовательными архитектурами и обосновать предлагаемую пространственно-временную графовую модель. Для достижения цели поставлены задачи: формализовать представление системы в виде графа; разработать архитектуру модели; провести сравнительный вычислительный эксперимент и оценить статистическую значимость различий.

Методы и материалы

Сложная инженерная система формализуется графом $G = (V, E, A)$, где V — множество вершин, соответствующих агрегатам или точкам измерения; E — множество рёбер, отражающих физические и функциональные связи; A — взвешенная матрица смежности. Каждой вершине v сопоставляется вектор признаков, формируемый из показаний относящихся к ней датчиков в пределах скользящего окна длиной w . Исходная топология задавалась по конструкторской документации, веса рёбер уточнялись по взаимной корреляции сигналов.

Предлагаемая пространственно-временная графовая модель (ST-GNN) сочетает графовый блок, агрегирующий признаки соседних вершин, с темпоральным блоком, учитывающим динамику сигналов. Обновление представления вершины на графовом слое описывается выражением (1):

$$h_v^{(l+1)} = \sigma(W^{(l)} \cdot AGG\{ h_u^{(l)} : u \in N(v) \}), \quad (1)$$

где $h_v^{(l)}$ — представление вершины v на слое l ; $N(v)$ — множество её соседей; AGG — перестановочно-инвариантная функция агрегирования; $W^{(l)}$ — обучаемая матрица; σ — нелинейная функция активации. Задача формулировалась как бинарная классификация наступления отказа на горизонте прогнозирования h , а качество оценивалось метриками F1 и PR-AUC, устойчивыми к классовому дисбалансу, а также средним упреждением прогноза. F1-мера вычислялась по формуле (2):

$$F1 = 2 \cdot P \cdot R / (P + R), \quad (2)$$

где P — точность (precision); R — полнота (recall). Для исключения утечки данных применялось хронологическое и пообъектное разбиение выборки в пропорции 70 / 15 / 15 %; параметры нормировки рассчитывались только по обучающей выборке. Тестовый корпус включал 1200 траекторий эксплуатации однотипных систем с размеченными по журналам отказами; каждая модель обучалась трижды, в таблицах приведены усреднённые значения. В сравнение включены логистическая регрессия, LSTM, TCN, Transformer, базовая GNN (GraphSAGE) и предлагаемая ST-GNN.

Результаты

Сводные результаты эксперимента приведены в таблице 1 и проиллюстрированы на рисунке 1. По всем метрикам наблюдается преимущество графовых архитектур над последовательными.

Таблица 1 — Сравнение моделей прогнозирования отказов

Модель	F1	PR-AUC	Упреждение, циклов
Логистическая регрессия	0,61	0,58	12
LSTM	0,74	0,71	21
TCN	0,76	0,73	23
Transformer	0,79	0,77	25
GNN (GraphSAGE)	0,83	0,82	28
ST-GNN (предлагаемая)	0,88	0,87	32

Как видно из таблицы 1, предлагаемая ST-GNN достигает F1-меры 0,88 против 0,79 у лучшей последовательной модели (Transformer), а среднее упреждение прогноза возрастает с 25 до 32 циклов, то есть примерно на 14 %. Базовая графовая модель GraphSAGE также превосходит последовательные архитектуры, что подтверждает значимость учёта топологии. Различия между графовыми и последовательными моделями статистически значимы по критерию Макнемара при уровне $p < 0,01$.




Рисунок 1 — Сравнение моделей по метрикам F1 и PR-AUC

Дополнительный анализ по типам отказов показал, что наибольший прирост графовые модели дают для каскадных отказов, охватывающих несколько связанных узлов, тогда как для локальных отказов одиночных агрегатов преимущество графового представления менее выражено. Это согласуется с гипотезой о том, что выигрыш GNN обусловлен именно учётом распространения деградации по структуре связей системы.

Заключение

В работе обоснована и экспериментально подтверждена эффективность применения графовых нейронных сетей для прогнозирования отказов в сложных инженерных системах. Предложенная пространственно-временная графовая модель, учитывающая топологию связей между агрегатами, превзошла последовательностные архитектуры по точности ($F1 — 0,88$) и обеспечила более раннее обнаружение предотказного состояния. Научная новизна состоит в формализации системы в виде динамического графа с уточнением весов рёбер по корреляции сигналов и в количественной оценке вклада топологии в качество прогноза. Практическая значимость результатов заключается в возможности их применения при построении систем предиктивного обслуживания энергетического, технологического и транспортного оборудования.

Литература

1. Хайкин С. Нейронные сети: полный курс. 2-е изд. М.: Вильямс, 2006. 1104 с.
2. Гудфеллоу Я., Бенджио И., Курвилль А. Глубокое обучение. М.: ДМК Пресс, 2018. 652 с.
3. Wu Z., Pan S., Chen F. [et al.]. A Comprehensive Survey on Graph Neural Networks // IEEE Transactions on Neural Networks and Learning Systems. 2021. Vol. 32, № 1. P. 4–24.

4. Yu B., Yin H., Zhu Z. Spatio-Temporal Graph Convolutional Networks // Proceedings of IJCAI. 2018. P. 3634–3640.
5. Hamilton W., Ying R., Leskovec J. Inductive Representation Learning on Large Graphs // Advances in Neural Information Processing Systems. 2017. Vol. 30. P. 1024–1034.
6. Lei Y., Yang B., Jiang X. [et al.]. Applications of Machine Learning to Machine Fault Diagnosis: A Review and Roadmap // Mechanical Systems and Signal Processing. 2020. Vol. 138. Art. 106587.

Literature

1. Haykin S. Neural Networks: A Comprehensive Foundation. 2nd ed. Moscow: Williams, 2006. 1104 p.
2. Goodfellow I., Bengio Y., Courville A. Deep Learning. Moscow: DMK Press, 2018. 652 p.
3. Wu Z., Pan S., Chen F. [et al.]. A Comprehensive Survey on Graph Neural Networks // IEEE Transactions on Neural Networks and Learning Systems. 2021. Vol. 32, no. 1. P. 4–24.
4. Yu B., Yin H., Zhu Z. Spatio-Temporal Graph Convolutional Networks // Proceedings of IJCAI. 2018. P. 3634–3640.
5. Hamilton W., Ying R., Leskovec J. Inductive Representation Learning on Large Graphs // Advances in Neural Information Processing Systems. 2017. Vol. 30. P. 1024–1034.
6. Lei Y., Yang B., Jiang X. [et al.]. Applications of Machine Learning to Machine Fault Diagnosis: A Review and Roadmap // Mechanical Systems and Signal Processing. 2020. Vol. 138. Art. 106587.