

УДК 681.514

Интеллектуализация процесса прогнозирования отказов оборудования на высоконадежных автономных объектах управления при помощи многомерного вариационного модального разложения с использованием нейронных сетей

Д.Н. Карпухин[✉], В.Л. Бурковский

Воронежский государственный технический университет, Воронеж, Россия

На оборудование высоконадежных автономных объектов управления, характеризуемое сложной и изменчивой рабочей средой, а также длительным временем непрерывной работы, в процессе эксплуатации влияют естественные факторы, в результате чего последовательность отказов колеблется, но в то же время имеет определенную периодичность. Прогнозирование отказов оборудования, имеет большое значение для рационального распределения ресурсов и составления планов по техническому обслуживанию. Для решения этой проблематики в данной статье исследуется модель прогнозирования, основанная на сочетании многомерного вариационного модального разложения с искусственными нейронными сетями, целью которой является повышение точности и достоверности прогнозирования, а также более точное отражение взаимосвязи между частотой отказов и множеством влияющих факторов.

Ключевые слова: высоконадежный автономный объект управления, многомерное вариационное модальное разложение, искусственные нейронные сети.

Intellectualization of the Process of Predicting Equipment Failures at Highly Reliable Autonomous Control Facilities Using Multidimensional Variational Modal Decomposition Using Neural Networks

D.N. Karpukhin[✉], V.L. Burkovsky

Voronezh State Technical University, Voronezh, Russia

The equipment of highly reliable autonomous control facilities, characterized by a complex and volatile working environment, as well as long continuous operation times, is influenced by natural factors during operation, as a result of which the sequence of failures varies, but at the same time has a certain frequency. Predicting equipment failures is of great importance for the rational allocation of resources and the preparation of maintenance plans. To solve the problem, this article examines a forecasting model based on a combination of multidimensional variational modal decomposition with artificial neural networks, which aims to increase the accuracy and reliability of forecasting, as well as more accurately reflect the complex relationship between the frequency of equipment failures and a variety of influencing factors.

Keywords: highly reliable autonomous control object, multidimensional variational modal decomposition, artificial neural networks.

Введение

В основе высоконадежного автономного объекта управления (ВОАУ) лежит способность позволяющая точно контролировать и обрабатывать данные в режиме

реального времени, для осуществления комплексного мониторинга состояния аппаратуры. Система мониторинга получает и анализирует данные с различных датчиков, для того чтобы гарантировать работу ВАОУ с максимальной эффективностью [1].

Отказы оборудования являются одним из негативных факторов в работе ВАОУ. Они представляют собой важный показатель для оценки эффективности его обслуживания. Вероятностью того, что какой-либо модуль выйдет из строя в течение определённого периода времени, является частота отказов. Она связана не только с затратами на техническое обслуживание и эксплуатацию, от неё также зависит безопасность системы. Поэтому переход на современные методы интеллектуального прогнозирования, является не просто желательным, а необходимым условием для повышения конкурентоспособности и экономической эффективности ВАОУ.

В настоящее время в области прогнозирования отказов используются классические статистические модели (КСМ), модели машинного и глубокого обучения. Преимущество статистических моделей заключается в простоте их применения, однако простота зачастую ограничивается линейной структурой, что вызывает трудности при анализе стохастических и нелинейных характеристик исследуемых объектов. Поэтому при применении КСМ в области прогнозирования отказов необходимо учитывать данное ограничение. Методы машинного и глубокого обучения идеально подходят для анализа вероятностей отказов, но сталкиваются с рядом проблем, к которым относятся возможность переобучения модели и недостаточная способность модели к обобщению данных. Современные подходы, применяемые при прогнозировании отказов, достигли определенного прогресса в своей области, однако большое разнообразие доступных методов затрудняет выбор наиболее подходящего для конкретного контекста. В данной статье рассматривается структура модели прогнозирования, которая базируется на объединении графовой нейронной сети (ГНН) и многомерного вариационного модального разложения (МВМР).

Графовая нейронная сеть

Естественные сбои в работе компонентов, происходят параллельно со сбоями, возникающими при эксплуатации оборудования, что оказывает негативное влияние на частоту возникновения отказов. Поэтому при работе с временными рядами, необходимо учитывать данную корреляцию между рассматриваемыми переменными. Для исследования данной зависимости идеально подходит графовая нейронная сеть, которая имеет способность к эффективному выявлению динамических закономерностей в параметрах данных.

Данный тип нейронных сетей может использоваться для анализа данных, которые реализованы в виде графов. В отличии от традиционных нейронных сетей, графовая нейронная сеть способна выявлять сложные закономерности, которые существуют между узлами и ребрами графа. Особенность архитектуры ГНН заключается в цикличной передаче информации между соседними узлами. Таким образом узлы, получившие информацию, учатся на данных, которые передали им соседи. Этот процесс представляет собой многоступенчатый обмен данными, в результате которого происходит постепенное обновление модели.

В необученной модели каждый узел графа имеет набор определенных признаков, которые характеризуют узел. Передача данных начинается с объединения информации между соседними узлами. Сбор информации между соседними узлами происходит при помощи функции агрегации. Данная функция позволяет учитывать

информацию об окружении графа, и затем полученная информация объединяется с собственным вектором узла, как показано в уравнении (1).

$$\begin{aligned} e_{ij} &= \text{Leaky ReLU}(Wh_i^{(t-1)} \| Wh_j^{(t-1)}), \\ \alpha_{ij} &= \frac{\exp(e_{ij})}{\sum_{j \in N_i} \alpha_{ij} Wh_j^{(t-1)}}, \\ h_i^{(t)} &= \sigma(\sum_{j \in N_i} \alpha_{ij} Wh_j^{(t-1)}), \end{aligned} \quad (1)$$

где e_{ij} является важностью характеристик узла j для узла i , Leaky ReLU является функцией активации, W – обучаемая матрица весов для линейного преобразования векторов узлов, $h_i^{(t-1)}$ – скрытое состояние узла i на предыдущем шаге, α_{ij} – коэффициент внимания между узлами i и j показывающий, насколько узел j важен для узла i , N_i является набором соседей узла i , а σ является нелинейной функцией активации.

Далее выполняется преобразование полученного объединенного вектора при помощи функции обновления состояния (ФОС). ФОС является нелинейной, что дает возможность ГНН создавать нелинейные зависимости в данных. Результат преобразования, становится новым вектором состояния узла h_i . Данный процесс повторяется несколько раз, что соответствует слоям ГНН. Количество слоев определяет глубину модели и ее способность использовать информацию из более удаленных частей графа. После завершения всех циклов, каждый узел модели имеет обновленный вектор состояния, который служит для её представлением, обогащенным данными из всего графа. Эти представления могут быть использованы для различных задач, включающих в себя классификацию узлов, предсказания взаимосвязей между ними, а также предсказания свойств всего графа. Существующие архитектуры ГНН, отличаются между собой методами объединения информации и методами обновления состояния, поэтому выбор конкретной модели зависит от специфики задачи и архитектуры графа. В настоящее время ведутся работы по разработке новых архитектур ГНН, которые сфокусированы на повышении способности обработки динамических данных, где структура графа может меняться с течением времени [4].

Многомерное вариационное модальное разложение

Многомерное вариационное модальное разложение представляет собой метод, используемый для обработки и анализа данных. Данный метод позволяет извлекать скрытую информацию из сложных многомерных временных рядов (МВР). Его отличие от традиционных методов анализа, таких как преобразование Фурье, заключается в заранее заданной базисной функции, которая формирует набор модальных составляющих, представляющих входной сигнал. Главной особенностью метода является наличие модального ансамбля, в котором каждая мода характеризуется своей полосой пропускания, определяемой смещениями гармоник, представляющих собой частотные характеристики моды. В основе метода МВР лежат решения задач выпуклой оптимизации, которые стремятся снизить количество мод, необходимых для получения заданной точности изменяемого сигнала. Данное решение достигается за счет поиска оптимального набора модальных функций, которые лучше всего подходят для объединения данных. Для повышения надежности результата в данном подходе применяются циклические методы оптимизации, которые способствуют повышению точности разложения сигнала и извлечению из него основных характеристик. Наличие

у МВМР способности к обработке сигналов, изменяющихся во времени, делает его подходящим методом для анализа данных, включающих в себя взаимосвязи между различными характеристиками сигнала [5].

Структурная схема модели прогнозирования МВМР-ГНН

На отказы оборудования ВАОУ влияют различные факторы. Между ними существует корреляционная зависимость, которая позволяет внедрить графовые нейронные сети для анализа сложных взаимосвязей и возможностей параллельных вычислений. Помимо этого, изменчивость и нестационарность в отказе оборудования, дает возможность применения МВМР для обработки многомерных временных рядов. Разложение МВР на несколько режимов, позволит уменьшить изменчивость и нестационарность данных. Структурная схема предлагаемой модели прогнозирования, основанной на сочетании МВМР с графовой нейронной сетью, представлена на рисунке.

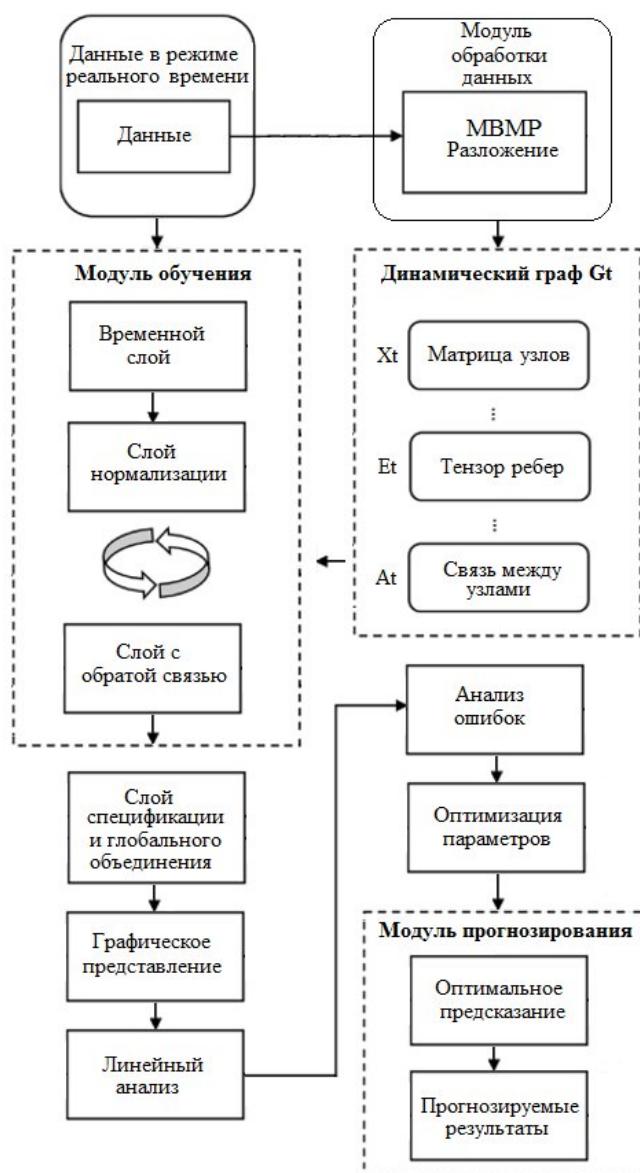


Рисунок. Структурная схема модели прогнозирования МВМР-ГНН

МВМР применяется для разложения исходного временного ряда на компоненты, чтобы уменьшить взаимное влияние периодической составляющей, а также уменьшить негативное влияние изменчивости исходного ряда на модель прогнозирования. Далее информация и взаимозависимости каждого временного ряда представляются на основе полученных собственных модальных компонентов с помощью динамического графа в ГНН. Динамический граф G_t этой модели определяется как тройка (X_t, E_t, A_t) , где X_t – матрица узлов, каждый узел которой содержит исторические значения временного ряда, E_t – это тензор рёбер, который представляет собой корреляцию между различными временными рядами, а A_t обозначает связь между узлами, где остатки временных рядов являются собственными тенденциями. Различия в тенденциях узлов отражаются в зависимости от того, насколько сильно коррелируют остатки временных рядов. Корреляция между остатками временных рядов x_i и x_j рассчитывается по формуле (2).

$$\rho_{ij} = \frac{\text{cov}(R_i, R_j)}{\sqrt{\text{var}(R_i) \cdot \text{var}(R_j)}}, \quad (2)$$

где R_i , R_j обозначают остатки последовательностей x_i , x_j , cov ковариацию R_i и R_j , а var обозначает дисперсию.

При построении матрицы смежности вычисляется корреляция трендов двух последовательностей узлов, и, если корреляция превышает определённый порог, эти две последовательности образуют рёбра, с помощью которых переменные со схожими трендами соединяются. В данной статье $A_t \in R^{N \times N}$, где $A_{ij} \in \{0,1\}$ обозначает связь между узлами, и определяется как показано в уравнении (3).

$$A_{ij}^t = \begin{cases} 1 & \text{if } |\rho_{ij}| > c \\ 0 & \text{otherwise} \end{cases}, \quad (3)$$

где параметр c обозначает пороговое значение корреляции, которое определяет, будет ли установлено ребро в матрице смежности A_{ij}^t между узлами i и j . Если $|\rho_{ij}| > c$, то между узлами i и j проводится ребро, если $|\rho_{ij}| \leq c$ ребро проводиться не будет.

Затем в модели необходимо учесть порядок и взаимосвязь элементов во временном ряду. Поэтому, чтобы улучшить восприятие взаимосвязи между позициями точек в последовательности и создать вектор представления на каждом узле используется рекуррентная нейронная сеть, которая заменяет позиционное встраивание благодаря возможности временного моделирования. Скрытое состояние h_i хранит информацию о предыдущей позиции i в последовательности, и может быть использовано для представления узла, а процесс его обновления показан в уравнении (4).

$$h_i = f(x_i, h_{i-1}; \theta_{RNN}), \quad (4)$$

где f – функция обновления, а θ_{RNN} – набор обучаемых параметров, который используют для вычисления скрытого состояния h_i . Данные параметры обучаются в процессе тренировки модели для эффективного кодирования временных зависимостей в последовательности.

Как показано в уравнении (5), при вычислении механизма внимания, который используется для взвешивания значимости элементов последовательности относительно друг друга, что позволяет модели динамически выделять важные

закономерности в данных, необходимо одновременно учитывать информацию о последовательности узлов, связях между узлами и структуре графа.

$$A_i = \left(\alpha_0 \sigma \left(\frac{Q_i K_i^T}{\sqrt{d_k}} \right) + \sum_{k=1}^K \alpha_k \sigma(D_{imfk}) + \alpha_{K+1} \cdot A \right) V_i, \quad (5)$$

где α_0 – обучаемый вес, регулирующий значимость этого слагаемого, σ является функцией активации, $Q_i K_i$ представляют из себя обучаемые проекции входных данных, d_k – размерность ключей для масштабирования скалярного произведения, α_k – обучаемые веса для разных аспектов структуры, D_{imfk} – матрица, кодирующая топологию графа. α_{K+1} – вес, регулирующий влияние связей между узлами, A является матрицей смежности графа.

Среди них первый член выполняет механизм самовнимания, позволяя модели адаптивно выбирать наиболее важные аспекты, тем самым улучшая предсказания для узлов, связанных в графе. Второй член содержит информацию о соответствующих характеристиках рёбер каждого временного ряда, а третий член содержит информацию о матрице смежности. Далее вводится функция перекрёстной энтропии, которая сравнивает ошибки между прогнозируемым результатом и истинным значением. Это применяется для того, чтобы определить, является ли ошибка меньше, чем наилучший прогноз. Для повышения надёжности, а также способности модели автоматически корректировать скорость обучения при изменении структуры данных используются адаптивный алгоритм и механизм корректировки скорости обучения для непрерывной итеративной оптимизации [6, 7].

Заключение

Стабильность работы оборудования напрямую влияет на безопасность эксплуатации ВАОУ в условиях ограниченных ресурсов. Использование передовых методов прогнозирования отказов имеет решающее значение для планирования стратегий технического обслуживания и повышения надёжности оборудования. В данной статье исследуется возможность применения модели прогнозирования временных рядов на основе МВМР-ГНН. Эта модель берет за основу преимущества глубокого обучения для обработки периодических последовательностей, уменьшает нелинейные характеристики используя многомерное вариационно-модальное разложение, а затем при помощи ГНН подгоняет тренд и степень колебаний последовательностей к частоте отказов. Учитывая сложную и изменчивую среду эксплуатации ВАОУ, объём собранных данных ограничен. Следующим шагом будет дополнение и улучшение исследуемых данных, для повышения точности и надежности модели прогнозирования.

СПИСОК ИСТОЧНИКОВ

1. Карпухин Д.Н. Структура системы управления внутренним электроснабжением автономного объекта энергообеспечения / Д.Н. Карпухин, В.Л. Бурковский // Завалишинские чтения 23: сборник докладов XVIII международной конференции по электромеханике и робототехнике. – Санкт-Петербург: Санкт-Петербургский государственный университет аэрокосмического приборостроения, 2023. – С. 221–225.
2. Хайкин С. Нейронные сети: полный курс, 2-е издание: Пер. с англ. / С. Хайкин. – Москва: Издательский дом «Вильямс», 2006. – 1104 с.

3. Холево А.С. Вероятностные и статистические аспекты квантовой теории: учебное пособие / А.С. Холево. – Москва: МЦНМО, 2020. – 364 с.
4. Флах П. Машинное обучение. Наука и искусство построения алгоритмов, которые извлекают знания из данных / П. Флах. – Москва: ДМК Пресс, 2015. – 400 с.
5. Большаков А.А. Методы обработки многомерных данных и временных рядов: учебное пособие / А.А. Большаков, Р.Н. Каримов. – Москва: Горячая линия-Телеком, 2007. – 522 с.
6. Хофер Э. Численные методы оптимизации / Э. Хофер, Р. Лундерштедт; пер. с нем. Т.А. Летовой; под ред. В.В. Семенова. – Москва: Машиностроение, 1981. – 192 с.
7. Шалев-Шварц Ш. Идеи машинного обучения: учебное пособие / Ш. Шалев-Шварц, Ш. Бен-Давид; пер. с англ. А.А. Слинкина. – Москва: ДМК Пресс, 2019. – 436 с.

ИНФОРМАЦИЯ ОБ АВТОРАХ

Карпухин Дмитрий Николаевич, аспирант кафедры электропривода, автоматики и управления в технических системах, Воронежский государственный технический университет, Воронеж, Россия.

e-mail: karpuxin.1996@mail.ru, тел.: +7 (473) 243-77-20

Бурковский Виктор Леонидович, доктор технических наук, профессор, профессор кафедры электропривода, автоматики и управления в технических системах, Воронежский государственный технический университет, Воронеж, Россия.

e-mail: bvl@vorstu.ru, тел.: +7 (473) 243-77-20