

УДК 681.514

Алгоритмизация пространственно-временного процесса построения графических моделей анализа потенциальных неисправностей в многомерных временных рядах с пропущенными значениями

Д.Н. Карпухин, В.Л. Бурковский

Воронежский государственный технический университет, Воронеж, Россия

Обнаружение предаварийных состояний и потенциальных неисправностей, имеет решающее значение для интеллектуальных систем мониторинга. Телеметрические данные, поступающие с датчиков высоконадежных автономных объектов управления плохо структурированы, в связи с чем возникает вероятность того, что некоторые значения в выборке пропущены. Наличие пропущенных значений препятствует эффективному моделированию временных и пространственных зависимостей, в результате чего важные закономерности упускаются из виду при обучении модели. В данной работе рассматривается пространственно-временной процесс построения графических моделей как средство выявления потенциальных неисправностей в многомерных временных рядах с пропущенными значениями.

Ключевые слова: мониторинг данных, метод обнаружения потенциальных неисправностей, высоконадежный автономный объект управления, многомерные временные ряды с пропущенными значениями.

Algorithmization of the space-time process of constructing graphical models for analyzing potential faults in multidimensional time series with missing values

D.N. Karpukhin, V.L. Burkovsky

Voronezh State Technical University, Voronezh, Russia

Detection of pre-emergency conditions and potential malfunctions is crucial for intelligent monitoring systems. The telemetry data coming from sensors of highly reliable autonomous control facilities is poorly structured, which makes it likely that some values in the sample are missing. The presence of missing values prevents effective modeling of temporal and spatial dependencies, as a result of which important patterns are overlooked when training the model. In this paper, the spatial-temporal process of constructing graphical models is considered as a means of identifying potential malfunctions in multidimensional time series with missing values.

Keywords: data monitoring, a method for detecting potential malfunctions, a highly reliable autonomous control object, multidimensional time series with missing values.

Различные отрасли промышленной индустрии круглосуточно генерируют телеметрические данные с многочисленных устройств и датчиков, формируя сложные многомерные временные ряды с тысячами переменных. В настоящее время накоплено достаточно большое количество информации о многомерных временных рядах, однако эта информация в основном демонстрирует нормальные зависимости, в то время как аномалии обычно связаны с редкими событиями, сбор и маркировка которых часто являются сложной задачей. В результате методы неконтролируемого обнаружения аномалий получили широкое распространение в качестве практического решения данной задачи, но несмотря на значительные достижения в этой области, проблема

поиска аномалий в нерегулярных многомерных временных рядах до сих пор не была хорошо изучена [1].

Трудности, возникающие при обнаружении аномалий в многомерных временных рядах с пропущенными значениями упрощенно представлены на рисунке.

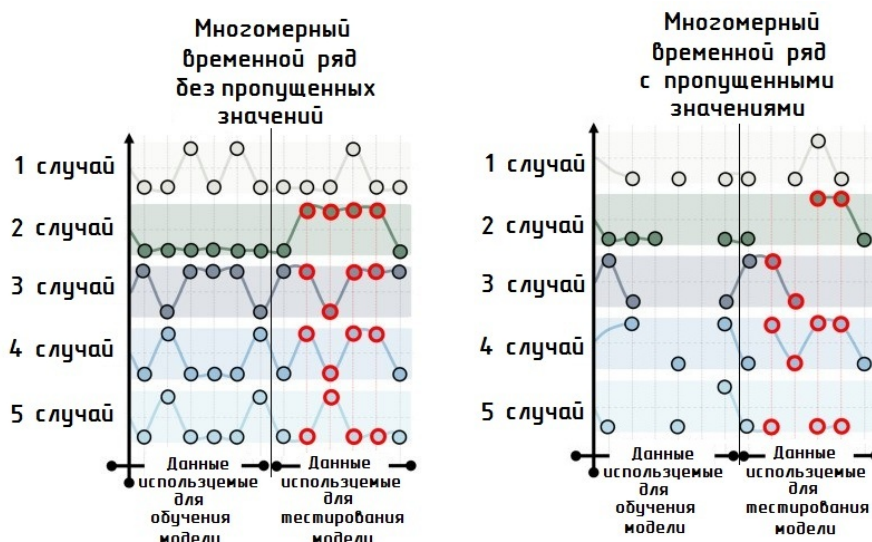


Рисунок. Упрощенное сравнение данных многомерных временных рядов без пропущенных значений(слева) и с пропущенными значениями (справа)

В первом случае на обоих графиках нет аномальных событий, но периодически регистрируется короткий всплеск значений. При настройке обычных рядов этому можно обучить модель, однако в нерегулярных многомерных временных рядах короткий всплеск значений может не регистрироваться в период обучения, и модели во время тестирования могут воспринимать события с короткими всплесками как аномальные. Поэтому, при настройке пропущенных значений нерегулярных многомерных временных рядов, высококачественных обучающих данных для обучения модели без учителя недостаточно. Во-втором случае, как показано на правом графике, наблюдаемые значения могут быть недоступны в течение некоторого аномального периода, что затрудняет обнаружение аномалий потоковых данных в реальном времени. Поэтому при мониторинге аномальных событий в режиме реального времени нельзя с уверенностью полагаться на наблюдаемые значения. В первом и втором случае показаны временные ряды, в которых значения переменных изменяются независимо, однако в большинстве случаев переменные в многомерных временных рядах тесно связаны. Последние три случая являются взаимосвязанными переменными, где третий случай имеет сильную отрицательную корреляцию с четвертым случаем, в то время как пятый случай имеет сильную положительную корреляцию с четвертым случаем и отклонение от этих взаимосвязей является аномальным событием. На правом графике рисунка можно наблюдать, что случай три записал конфликтующие значения с четвертым случаем только для первых двух ранних временных точек, но не для последующих аномальных значений. В случае пять напротив, регистрируются аномальные значения в более поздние периоды. Поскольку маловероятно, что все каналы одновременно имеют пропущенные значения, можно предположить, что модель полностью отражает взаимозависимость между переменными, и, даже если данные страдают от высокой частоты пропущенных значений, модель может обнаруживать аномальные события в нерегулярных многомерных временных рядах.

Методы обнаружения аномалий в многомерных временных рядах с пропущенными значениями

Многие классические модели прогнозирования, такие как ARIMA, построены таким образом, что после оптимизации на обычных обучающих данных модель делает прогноз на один шаг вперед для текущей временной метки. Затем прогнозируемые значения сравниваются с наблюдаемыми значениями, чтобы определить, насколько аномальной является текущая временная метка. Методы, обнаруживающие аномалии посредством ошибок реконструкции, включают изучение представления нормальных обучающих рядов и выводят реконструкцию входных данных с потерями. Поскольку изученное представление оптимизировано для обычных данных, в аномальные периоды вероятно высокая ошибка восстановления. Несмотря на то, что оба метода хорошо изучены, они имеют ряд ограничений в захвате нелинейных пространственных и временных взаимосвязей, присущих данным многомерных временных рядов.

Проблема обнаружения аномалий в многомерных временных рядах – это ключевая задача в различных интеллектуальных системах мониторинга. С развитием глубокого обучения (DL) на первый план вышла нейронная сеть с долговременной кратковременной памятью (LSTM), которая использует ошибки прогнозирования для идентификации аномалий [2]. LSTM обладает способностью обрабатывать последовательные данные и запоминать долгосрочные зависимости, что позволяет ей эффективно выявлять отклонения от нормального поведения. Однако LSTM имеет существенный недостаток – она не моделирует явно парные зависимости между переменными, которые часто встречаются в реальных данных. Это ограничение может препятствовать эффективному обнаружению сложных аномальных событий в многомерных временных рядах, особенно в тех, где размерность данных велика. Для преодоления этого недостатка были разработаны методы, основанные на нейронных сетях с графами (GNNs). MTAD-GAT и GDN – два таких метода, которые используют пространственно-временные графовые нейронные сети (STGNNs) для моделирования пространственных и временных корреляций данных. На сегодняшний день в сфере обнаружения аномалий в многомерных временных рядах STGNNs занимают лидирующее положение, демонстрируя превосходные результаты. Используя графические нейронные сети, они способны эффективно анализировать сложные взаимосвязи между различными параметрами во временных рядах, что позволяет точно идентифицировать отклонения от нормального поведения. Однако традиционные STGNNs часто сталкиваются с трудностью обработки временных рядов с нерегулярным временным шагом, что затрудняет их применение в реальных сценариях. Для преодоления этой проблемы была принята во внимание модификация STGNN, включающая пространственно-временной модуль DG-NCDE. Данный модуль предназначен для обработки нерегулярных временных рядов и основан на идее динамического графа, который адаптируется к изменяющейся плотности данных во времени. Он использует непрерывную нормализованную оценку плотности (CNDE), чтобы уловить нелинейные зависимости между данными и определить аномалии с высокой точностью. В результате, модифицированная STGNN с DG-NCDE модулем представляет собой мощный инструмент для обнаружения аномалий в многомерных временных рядах с нерегулярным временным шагом [3, 4].

Общая архитектура пространственно-временного процесса построения графических моделей

Пространственно-временной процесс построения графических моделей (ПВПГМ) включает два ключевых компонента: блок прогнозирования на основе

DG-NCDE и детектор аномалий на основе гауссовой оценки. ПВППГМ вычисляет пропущенные значения для формирования непрерывных траекторий. Затем, при составлении прогноза на один шаг вперед, используется предполагаемый набор непрерывных путей для оптимизации модуля прогнозирования. Оптимизируя эти процессы для прогнозирования, модель может эффективно распознавать неаномальные пространственно-временные зависимости из обычных обучающих данных.

При отсутствии аномалий модуль будет выдавать нормальные прогнозы, аналогичные значениям в неаномальных обучающих данных. И наоборот, в периоды аномалий модуль будет генерировать выходные данные, которые значительно отклоняются от обычных прогнозов. Основываясь на этой концепции, предлагается система оценки аномалий, которая рассматривает аномальность прогнозируемых значений путем анализа вероятности аномалий в каждой временной метке. Следовательно, нерегулярно наблюдаемые значения используются исключительно для прогнозирования на один шаг вперед, в то время как анализ аномалий вычисляется оценщиком исключительно на основе исторических и текущих прогнозов

Динамический график дифференциальных уравнений с нейронным управлением

Многомерный временной ряд обычно рассматривается как динамический график с дискретным временем, состоящий из снимков графика с регулярной выборкой, обозначаемых:

$$G_t = (V, E, x(t)), \quad (1)$$

где V и E определяют заранее заданную структуру графика для последовательности наблюдений, характеризующую базовую связь между переменными (датчиками), в то время как $x(t)$ относится к узловым элементам моментального снимка G_t во времени t .

Однако на практике пропущенные значения могут присутствовать как в переменных, так и во временных измерениях выборки данных или сбоев датчиков, что создает серьезную проблему для использования готовых нейронных сетей с динамическими графами в качестве модели для встраивания многомерных временных рядов. Данную проблему можно решить при помощи дифференциального уравнения с нейронным управлением на динамическом графике (DG-NCDE), независимо от наличия пропущенных значений в данных [5]. NCDE построено на основе обыкновенных нейронных дифференциальных уравнений, конечной целью которых является изучение функции CDE $f(q)$, параметризованный q из данных. Формулировка дифференциального уравнения с нейронным управлением (NCDE) показана в уравнении (2).

$$Z(\tau) = Z(t_0) + \int_{t_0}^{\tau} f(Z(t); \theta) dX(t) = Z(t_0) + \int_{t_0}^{\tau} f(Z(t); \theta) \frac{dX(t)}{dt} dt, \quad (2)$$

где скрытое состояние $Z(t)$ управляется с течением времени на основе $X(t)$, который обозначает непрерывный путь, полученный из дискретных наблюдений X . В этом отношении NCDE можно рассматривать как непрерывную версию рекуррентных нейронных сетей (RNN), которая демонстрирует превосходную производительность во многих тестах временных рядов. Хотя NCDE проливают свет на моделирование реальных одномерных временных рядов, остается неясным, как моделировать динамические графики (с дискретным временем) с помощью NCDE. Устранить этот пробел можно следующим уравнением, которое объединяет пространственные и временные процессы вместе.

$$Z(\tau) = Z(t_0) + \int_{t_0}^{\tau} f((Z(t); \theta) g(H(t); \Phi) \frac{dX(t)}{dt} dt. \quad (3)$$

Здесь $g(\Phi)$ и $f(q)$ обозначают пространственные и временные функции NCDE, каждая из которых параметризована различными наборами, разработанными для моделирования внутренней пространственной и временной динамики входных данных. Формулировка, представленная в уравнении, может быть рассмотрена как подход непрерывного времени к моделированию динамического графика с дискретным временем. Однако отличительной особенностью DG-NCDE является его способность моделировать данные многомерных временных рядов независимо от наличия пропущенных значений.

Пространственный процесс

Для моделирования скрытого состояния каждой переменной, контролируемой непрерывным путем $X(t)$, между снимками графика необходимо определить пространственный NCDE с границами $t_0 := T - w_s$ и $\tau := T - 1$ следующим образом:

$$H(\tau) = H(t_0) + \int_{t_0}^{\tau} g(H(t); \Phi) \frac{dX(t)}{dt} dt. \quad (4)$$

Для формулировки пространственной функции NCDE $g(H(t); \Phi)$ необходимо сделать аппроксимацию свертки графика полиномом Чебышева первого порядка, как показано в следующем уравнении:

$$g(H(t); \Phi) = FC^{(1)} \left(D^{-\frac{1}{2}} - AD^{-\frac{1}{2}} - H(t) W_s \right), \quad (5)$$

где $H(t) = \text{ReLU}(FC^{(0)}(H(t)))$, $A = A + I$ и D обозначает диагональную матрицу степеней A . В случае предопределенной матрицы смежности графа A , необходимо изучить его от начала до конца со всей моделью, т. е. $A := \text{ReLU}(E \cdot E^T)$, где E – обучаемая матрица.

Временной процесс

Для моделирования временных зависимостей, используется процесс temporal NCDE. Формально этот процесс можно описать следующим уравнением:

$$Z(\tau) = Z(t_0) + \int_{t_0}^{\tau} f(Z(t); \theta) \frac{dH(t)}{dt} dt, \quad (6)$$

где $f(Z(t); \theta)$ – это временная функция NCDE, которая отслеживает скрытые траектории $Z(t)$ в течение времени контролируемым непрерывным путем $H(t)$, который генерируется пространственным процессом. Существует широкий спектр реализаций $f(Z(t); \theta)$. В этой статье был выбран метод, который включает следующее моделирование:

$$f(Z(t); \theta) = \phi \left(FC^{(0)} Z_0(t) \right) \parallel \dots \parallel \phi \left(FC^{(N-1)} Z_{N-1}(t) \right), \quad (7)$$

где ϕ и \parallel обозначим активацию ReLU и операцию конкатенации соответственно.

Представленная формула DG-NCDE объединяет пространственные и временные процессы для моделирования многомерного временного ряда. Это позволяет прогнозировать будущие точки данных путем передачи изученных представлений временных рядов через дополнительный полностью связанный уровень, действующий как нисходящий прогнозист.

Оценка аномалий

Для разработки надежного средства оценки аномалий, которое обрабатывает временные ряды с пропущенными значениями, ПВППГМ оценивает аномалии в каждой временной метке без необходимости доступа к реальным наблюдаемым значениям в текущей временной период. В частности, с текущей временной меткой T , единственными необходимыми входными данными для оценки аномалий ПВППГМ являются текущие и исторические прогнозы $\{\hat{y}^{(1)}, \dots, \hat{y}^{(T)}\}$ из модуля прогнозирования.

Для каждого канала сначала вычисляется вероятность аномалии, $\alpha(t_i)$ текущего прогноза путем вычисления отрицательной логарифмической вероятности прогнозируемого значения с опережением на один шаг после подгонки скользящего гауссова распределения к прошлым и текущим значениям прогноза:

$$\alpha_i^{(t)}(y_i^{(t)} | \mu_i^{(t)}, \sigma_i^{(t)}) = \ln \sigma_i^{(t)} + \frac{1}{2}(2\pi) + \frac{1}{2} \left(\frac{y_i^{(t)} - \mu_i^{(t)}}{\sigma_i^{(t)}} \right)^2, \quad (8)$$

где $\mu_i^{(t)}$ и $\sigma_i^{(t)}$ представляют среднее значение и стандартное отклонение параметра нашего скользящего распределения по Гауссу:

$$\mu_i^{(t)} = \frac{1}{W} \sum_{j=0}^{W-1} y_i^{(t-j)}; (\sigma_i^{(t)})^2 = \frac{1}{W} \sum_{j=0}^{W-1} (y_i^{(t-j)} - \mu_i^{(t)})^2, \quad (9)$$

где W – размер окна аномалий, $W - 1$ – значение из обучающих данных для вычисления гауссовых параметров $\mu_i^{(t)}$ и $\sigma_i^{(t)}$ для $t < W$. Для окончательной оценки аномалий $A^{(t)}$ в каждой временной метке необходимо линейно агрегировать вероятность аномалии для каждого канала:

$$A^{(t)} = \sum_{i=1}^M \alpha_i^{(t)}. \quad (10)$$

Современные подходы в первую очередь полагаются на наблюдаемые значения для вычисления оценки аномалии в форме реконструкции или ошибок прогнозирования. В то время как ошибки прогнозирования позволяют просто обнаруживать аномальные события на основе отклонения между прогнозируемыми и реальными значениями. На реальные наблюдения нельзя безопасно полагаться в сценарии с нерегулярными временными рядами, поскольку они постоянно отсутствуют и недоступны [6, 7].

Выводы. В данной работе был рассмотрен подход для решения проблемы обнаружения аномалий в нерегулярных многомерных временных рядах. Структура основана на предположении, что ПВППГМ может предсказывать значения, которые вырождаются и отклоняются от нормальных результатов прогнозирования в аномальные периоды, но напоминают прогнозные значения в течение неаномального периода. Другими словами, пока в сигналах скользящего окна ввода присутствует пространственная и/или временная аномалия, ПВППГМ должен генерировать прогнозы, которые также являются аномальными. И наоборот, он должен генерировать прогнозные значения, аналогичные прогнозным выводам, сделанным для неаномальных обучающих данных, если на входе нет аномальных сигналов. В будущем планируется убедиться, что ПВППГМ превосходит современные показатели обнаружения аномалий в многомерных временных рядах не только в обычных настройках, но и в сценариях с высокой частотой пропущенных значений, тем самым проложив путь для внедрения методов STGNN в реальные приложения.

СПИСОК ИСТОЧНИКОВ

1. Хеннан Э.Д. Многомерные временные ряды / Э.Д. Хеннан. – Москва: Мир, 1974. – 576 с.
2. Карпухин Д.Н. Алгоритмизация процесса мониторинга данных на автономных объектах электропитания в условиях прогнозирования потенциальных неисправностей на основе однородного глубокого нейронного ансамбля / Д.Н. Карпухин, В.Л. Бурковский // Вестник Воронежского института высоких технологий. – 2024. – Т. 18. – № 2 (49). – URL: <https://vestnikvvt.ru/ru/journal/pdf?id=1327> (дата обращения: 15.08.2024).
3. Созыкин А.В. Обзор методов обучения глубоких нейронных сетей / А.В. Созыкин // Вестник ЮУрГУ. Серия «Вычислительная математика и информатика». – 2017. – Т. 6. – № 3. – С. 28-59.
4. Хайкин С. Нейронные сети: полный курс, 2-е издание / С. Хайкин. – Москва: Издательский дом «Вильямс», 2006. – 1104 с.
5. Юсупбеков Н.Р. Управление динамическими объектами на основе нейронных сетей / Н.Р. Юсупбеков, Д.П. Мухитдинов, О.У. Саттаров // Journal of Advances in Engineering Technology. – 2021. – Т. 1. – № 3. – С. 55-63.
6. Калиткин Н.Н. Численные методы / Н.Н. Калиткин. – Москва: Наука, 1978. – 512 с.
7. Отнес Р. Прикладной анализ временных рядов: основные методы / Р. Отнес, Л. Эноксон. – Москва: Мир, 1982. – 428 с.

ИНФОРМАЦИЯ ОБ АВТОРАХ

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

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