

Подход к повышению качества моделей машинного обучения в задачах мониторинга сложных систем на основе применения метрических пространств

М.А. Большаков, В.А. Ходаковский

*Петербургский государственный университет путей сообщения императора
Александра I*

Аннотация: В работе предлагается подход, позволяющий повысить эффективность использования моделей машинного обучения в задачах мониторинга на основе использования метрических пространств. Под эффективностью при этом понимается решение ключевых задач мониторинга – повышение заблаговременности, выявление нежелательных инцидентов и снижение, по возможности, ложных срабатываний системы. Подход носит универсальный характер и не зависит от конкретных алгоритмов машинного обучения (в основном, методов классификации) и способов измерения расстояния между элементами метрического пространства. Подбор наилучшей комбинации методов осуществляется путем перебора на основе предложенной методики. Подход апробирован на наборе синтетических и реальных данных.

Ключевые слова: мониторинг, машинное обучение, классификация состояний, прогнозирование инцидентов, заблаговременность, выявление аномалий.

Введение

Оценка эффективности систем мониторинга сложных систем, характеризующихся большим числом измеряемых параметров (метрик мониторинга), требует разработки специальных подходов, определяемых способом выявления потенциально опасных ситуаций, грозящих возникновением нежелательных событий (инцидентов). Большое число измеряемых параметров практически исключает возможность установки пороговых значений [1], при пересечении которых требуется внимание оператора системы или срабатывание механизмов предотвращения опасной ситуации, так как при большом числе факторов критическая ситуация может характеризоваться комбинацией параметров, а не просто аномальным отклонением одного или нескольких параметров от типовых или усредненных значений.

В результате попытка выстроить систему порогов приводит к структуре данных, похожей на дерево решений, построение которого в настоящее время может быть эффективно автоматизировано с применением методов машинного

обучения, так как для обоснованного выставления порогов в любом случае требуется не только спецификация оборудования или технической системы, но и накопленная история эксплуатации, включающая случаи отказов оборудования или других форм нежелательных событий.

Развитие подхода с применением методов машинного обучения приводит к большому числу альтернативных алгоритмов, позволяющих интерпретировать инциденты как события во временном ряду измеряемых параметров, характеризуемые временной меткой с соответствующим классом. Тогда, с математической точки зрения, задача сводится к поиску паттернов во временных рядах, характерных для нежелательных ситуаций, а в более узкой интерпретации - к задаче классификации среза временного ряда, где признаками для модели машинного обучения выступают значения измеряемых параметров. Для большинства случаев подходит бинарная классификация, где классы можно интерпретировать как нормальное и аномальное состояние системы.

Такой подход является относительно устойчивым в связи с активным развитием соответствующих методов и прогрессом в аппаратной части вычислительных систем. Однако, специфика задачи мониторинга заключается в необходимости не просто определить опасную комбинацию параметров, а выявить ее с некоторой степенью заблаговременности.

Традиционно данное требование выполнялось путем установки более низких порогов срабатывания системы предупреждения, однако, как указано выше, обоснованная установка нужных значений значительно усложнена для сложных технических систем с большим числом измеряемых параметров и неизвестной формой их взаимного влияния.

Кроме заблаговременности, другой важнейшей характеристикой системы мониторинга является количество ложных срабатываний.

В итоге качественная система мониторинга должна обеспечивать баланс противоречивых требований: обеспечивать *заблаговременность* выявления потенциального инцидента, не пропускать угрозы возникновения опасных

ситуаций и не допускать *ложных срабатываний*, снижающих доверие к результатам работы системы мониторинга в целом.

Для решения указанной задачи в работе предлагается способ оценки качества мониторинга на основе модифицированных метрик машинного обучения, а также предложены способы улучшения этих метрик за счет применения метрических пространств в комбинации с базовым классификатором, обученном на предыстории работы системы мониторинга.

Обзор существующих решений

Исследование относится к области предиктивной аналитики оборудования (predictive maintenance) области, в которой применяется практически весь арсенал современного математического аппарата, включая методы машинного обучения [2].

Популярные методы относятся к двум основным классам: регрессионные, позволяющие прогнозировать конкретные параметры оборудования или системы на несколько шагов вперед, и классификационные, которые оценивают состояние системы в целом по набору текущих значений измерений. Регрессионные методы, в целом, являются более сложными и требуют, как правило, более высокого уровня от разработчиков. Кроме того, само по себе знание параметров системы на несколько шагов вперед не дает достаточной информации об уровне имеющейся угрозы, и задача в оценке текущего состояния сводится к задаче классификации или в более традиционной постановке к установке пороговых значений на ключевые параметры, что также, в целом, разделяет (классифицирует) состояние на неопасное и опасное.

В работе рассматривается только второй подход к оценке состояний на основе методов классификации, который с одной стороны является более универсальным, а с другой также способен обеспечить заблаговременность (earliness) выявления угрожающих состояний системы.

Главной особенностью применения методов машинного обучения к задачам мониторинга является работа с временными рядами, для которых требуется особый подход к интерпретации результатов моделирования. Применительно к задачам прогнозов временных рядов ситуация довольно однозначная – самыми популярными метриками являются MSE, RMSE, MAE и MAPE [3], и данная ситуация практически не меняется с начала 80-х годов [4]. При классификации состояний во временных рядах наиболее релевантным формализмом является задача выявления аномалий (anomaly detection), для которой способы оценки качества результатов детектирования являются существенно более разнообразными [5].

Помимо традиционных метрик точности (Precision) и полноты (Recall) [6] предлагается довольно много дополнительных метрик [7], таких как ASC (среднее количество сегментаций), ASD (абсолютное расстояние сегментации), ADT (среднее направление тенденции), ADC (среднее количество обнаружения) и ADD (абсолютная дальность обнаружения). Ключевым моментом в интерпретации детектирования аномалий является расхождение в точном моменте выявления аномалии классификатором и фактическом обнаружении аномалии в другой, возможно близкий, момент времени. Для этого вводятся дополнительные понятия:

- Точное совпадение (Exact Match). Ситуация, когда аномалия из результатов классификации точно совпадает с аномалией в целевой классификации.
- Обнаруженная аномалия (Detected Anomaly). Ситуация, когда аномалия-кандидат не совпадает точно с целевой аномалией в пределах рассматриваемого диапазона. Если аномалия находится в пределах этого диапазона, она рассматривается как обнаружение. Однако эта аномалия-кандидат также будет учтена как ложная аномалия (False Anomaly), что порождает значительную неопределённость в общих результатах оценки качества работы классификатора.

Кроме того, понятие «рассматриваемого диапазона» не является строго формализованным и требует в каждом случае специального подхода для его определения. Точное совпадение в контексте задач мониторинга не является целью большинства систем, так как при этом не решается ключевая задача превентивного или проактивного реагирования. Для этого необходимо обеспечивать заблаговременность обнаружения опасной ситуации, не порождая при этом значительного числа ложных срабатываний [8]. Для этой задачи был предложен отдельный тип моделей, называемый ранняя классификация временных рядов (the early classification of time series, ECTS).

Ключевым аспектом этой задачи является как раз обеспечение раннего обнаружения аномалии без критической потери точности классификации, так как указанные требования являются противоречивыми по своей природе.

Такая задача не может считаться решенной, так как в открытых источниках регулярно появляются новые работы по данной тематике [8,9]. Стоит отметить еще один термин, относящийся к оценке качества мониторинга, а именно мощность сигнала тревоги (alarm cardinality), который разделяет ситуации по степени опасности, например на основе оценки вероятности классификатора и правил останова (stopping rule) [10].

Оценка качества системы мониторинга

Исследование относится к области предиктивной аналитики оборудования (predictive maintenance) области, в которой применяется практически весь арсенал современного математического аппарата, включая методы машинного обучения [1].

При оценке качества системы мониторинга предлагается перейти от точечной оценки временных срезов с набором характеристик к интервальной оценке, интерпретируемой как период времени, требующий реакции оператора на возможный инцидент.

Расчет этого интервала является нетривиальной задачей, так как отсутствует эталонное значение границ интервала и его невозможно классифицировать традиционными методами машинного обучения, в отличие от самого момента возникновения инцидента.

В базовой постановке задача машинного обучения также сводится к классификации нормального и потенциально опасного состояния системы, однако в системах мониторинга необходимо учитывать связность состояний системы в соседние моменты времени.

В итоге, для оценки интервала (зоны реакции) предлагается использовать значение вероятности (probability, $p \in (0,1)$) возникновения инцидента. Этот параметр рассчитывается подавляющим большинством алгоритмов машинного обучения, однако требует аккуратной интерпретации, так как не является истинной вероятностью с точки зрения математической статистики.

В итоге предлагается следующий способ выявления зон реакции:

1. Выявить момент времени i , когда значение вероятности p_i отнесения ситуации к инциденту выше порогового значения, обычно это значение равно 0.5. Этот момент считается началом *зоны реакции*, когда оператору следует обратить внимание на повышенную вероятность возникновения инцидента.

2. Добавлять единицу времени к интервалу, пока значение вероятности держится выше порогового значения: $p_j > 0.5$, где $j > i$.

3. Момент времени пересечения порогового значения вероятности вниз (ниже 0.5) считается окончанием зоны реакции.

Особенностью подхода является неровный характер вероятности, который на некотором промежутке времени может несколько раз пересекать пороговое значение (см. рис. 1), поэтому для повышения эффективности мониторинга, особенно в плане заблаговременности, предлагается скомбинировать вероятность с дополнительной характеристикой, интерпретируемой как «расстояние до зоны инцидента».

Это расстояние можно рассчитать различными способами, но главное требование к данной величине – это меньшая чувствительность к параметрам системы по сравнению с базовым классификатором.

Для расчета расстояния требуется ввести метрическое пространство из точек – срезов измеряемых параметров системы мониторинга, и предложить способ расчета расстояний в нормированном виде для обеспечения возможности интерпретации результатов. В таком случае способ выявления зон реакции следует скорректировать на следующий:

1. Выявить момент времени i , когда значение вероятности p_i отнесения ситуации к инциденту и нормированное расстояние до инцидента d_i^{norm} одновременно выше порогового значения. В обоих случаях выбирается значение 0.5. Этот момент считается началом *зоны реакции*.

2. Добавлять единицу времени к интервалу, пока значение только нормированного расстояния до инцидента держится выше порогового значения: $d_i^{norm} > 0.5$, где $j > i$.

3. Момент времени пересечения порогового значения вероятности p_j независимо от значения расстояния d_j^{norm} вниз (ниже 0.5) считается окончанием зоны реакции.

Второй подход позволяет несколько более грубо оценивать зоны реакции на инцидент, но, с другой стороны, за счет меньшей волатильности уменьшается число ложных отбоев от опасности в случаях, когда угроза инцидента остается высокой, хотя значение вероятности падает ниже критического уровня.

Типовой ситуацией является короткий интервал времени, когда вероятность p_j несколько раз пересекает пороговые значения, из-за чего возникают ситуации, которые можно интерпретировать как ложные отбои.

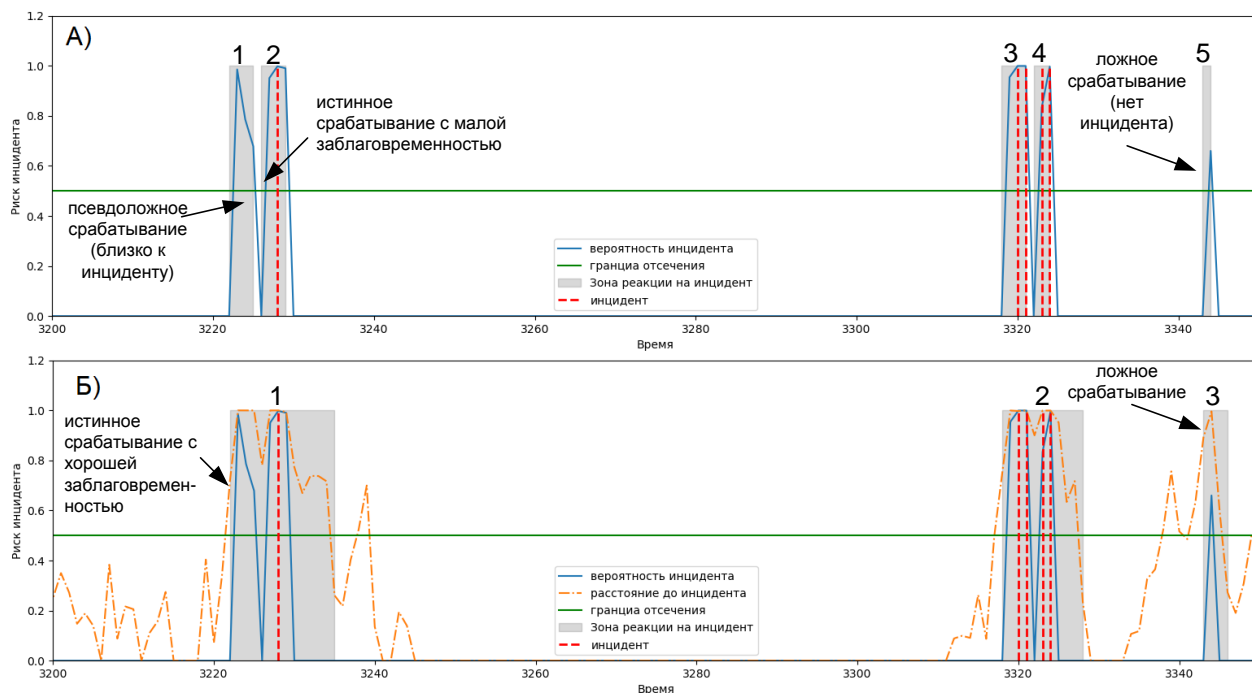


Рис. 1. – Визуализация результатов классификации опасных состояний системы в интервальной форме на тестовом фрагменте данных на основе (А) только вероятности класса инцидентов, (Б) комбинации вероятности класса инцидента и расстояния до ранее наблюдаемых инцидентов

Из рисунка 1 видно, что во втором случае зоны реакции расширяются (за счет объединения нескольких зон с высокой вероятностью инцидента), а потенциальная заблаговременность увеличивается. В итоге количество зон реакции уменьшилось с 5 до 3, что автоматически повышает и заблаговременность обнаружения. Количество корректно обнаруженных инцидентов в обоих случаях одинаково, как и количество ложных срабатываний (одно в обоих случаях).

Чтобы количественно оценить эффективность мониторинга через метрики, теперь можно оценивать попадание или непопадание реально возникшего инцидента в зону реакции. Соответственно, возможны следующие ситуации:

1. Если инцидент попал в зону реакции, то ситуации интерпретируются как истинно положительные (true positive).

2. Если был выявлен интервал реакции, но инцидент не произошел, то событие интерпретируется как ложно положительное (false positive). Другими словами – ложное срабатывание.

3. Если инцидент возник, но не попал в зону реакции, то событие интерпретируется как ложно отрицательное (false negative).

В итоге по классическим формулам можно оценить точность (precision) и полноту (recall), которые в случае точечной интерпретации каждого момента времени как независимого события теряли бы смысл из-за избыточного числа ложных срабатываний классификатора. При этом точность можно интерпретировать как долю выявляемых инцидентов, а полноту как индикатор ложных срабатываний.

В обоих случаях, чем больше значение индикатора, тем лучше. Значение 1 для точности означает, что все возникшие инциденты учтены, а для полноты значение 1 означает, что не было зафиксировано ложных срабатываний. Заблаговременность рассчитывается как разность между моментом времени возникновения инцидента и началом зоны реакции в тестовой выборке.

Среди особенностей подхода следует отметить, что выделение зоны реакции зависит от используемого классификатора, однако само по себе это не является проблемой, так как можно подобрать из множества доступных классификаторов тот, который обеспечивает наилучшие значения метрик и заблаговременности.

Расчет расстояний для оценки близости к инцидентам

Расчет расстояний целесообразно осуществлять при нормированных компонентах вектора состояний. Для этого можно применить стандартные нормализаторы данных (например, Standart Scaler), однако в случае большого числа компонент (измеряемых параметров системы) этого может быть недостаточно по той причине, что разные компоненты вносят принципиально разный вклад в точность классификации опасных состояний.

По этой причине сам ряд значений измеряемых величин имеет смысл понизить в размерности до небольшого числа компонент. В качестве возможного улучшения способа вычисления расстояний можно нормализовать в том числе компоненты вектора в пространстве пониженной размерности путем умножения на значимость признаков используемого классификатора.

Обычно первый компонент в новом пространстве значительно превосходит по значимости второй и последующие компоненты, что также влияет на объективность рассчитываемых расстояний: чем больше значимость компонента с точки зрения классификации, тем больший вклад он должен вносить в расчет расстояний.

На рисунке 2 приведен пример снижения исходного пространства параметров мониторинга с 20 до 2-х с использованием алгоритма Truncated SVD, что также позволяет интерпретировать оценки расстояний и отслеживать динамику процесса.

В этом примере для работы алгоритма классификации обязательно требуется выравнивание классов (нормальное состояние системы и инциденты), так как в реальных системах соотношение данных классов составляет от 1/100 и выше, что является неприемлемым дисбалансом для алгоритмов машинного обучения.

В примере используется популярный алгоритм SMOTE, хотя потенциально можно использовать несколько других алгоритмов подобного класса. Для снижения размерности также можно применять множество других алгоритмов соответствующего класса, которые также несложно подобрать путем перебора в силу ограниченности их перечня [9,11]. Проблема обучения моделей на несбалансированных данных хорошо известна и часто встречается в прикладных задачах, для решения которых используются методы машинного обучения [12].

Для эффективного вычисления расстояний в силу большого количества объектов целесообразно использовать специальные структуры данных, такие как деревья квадрантов (KD Tree), а в качестве метрики расстояния рационально

использовать расстояние Минковского, хотя предлагаемый подход в целом применим к любым способам измерения расстояний между объектами.

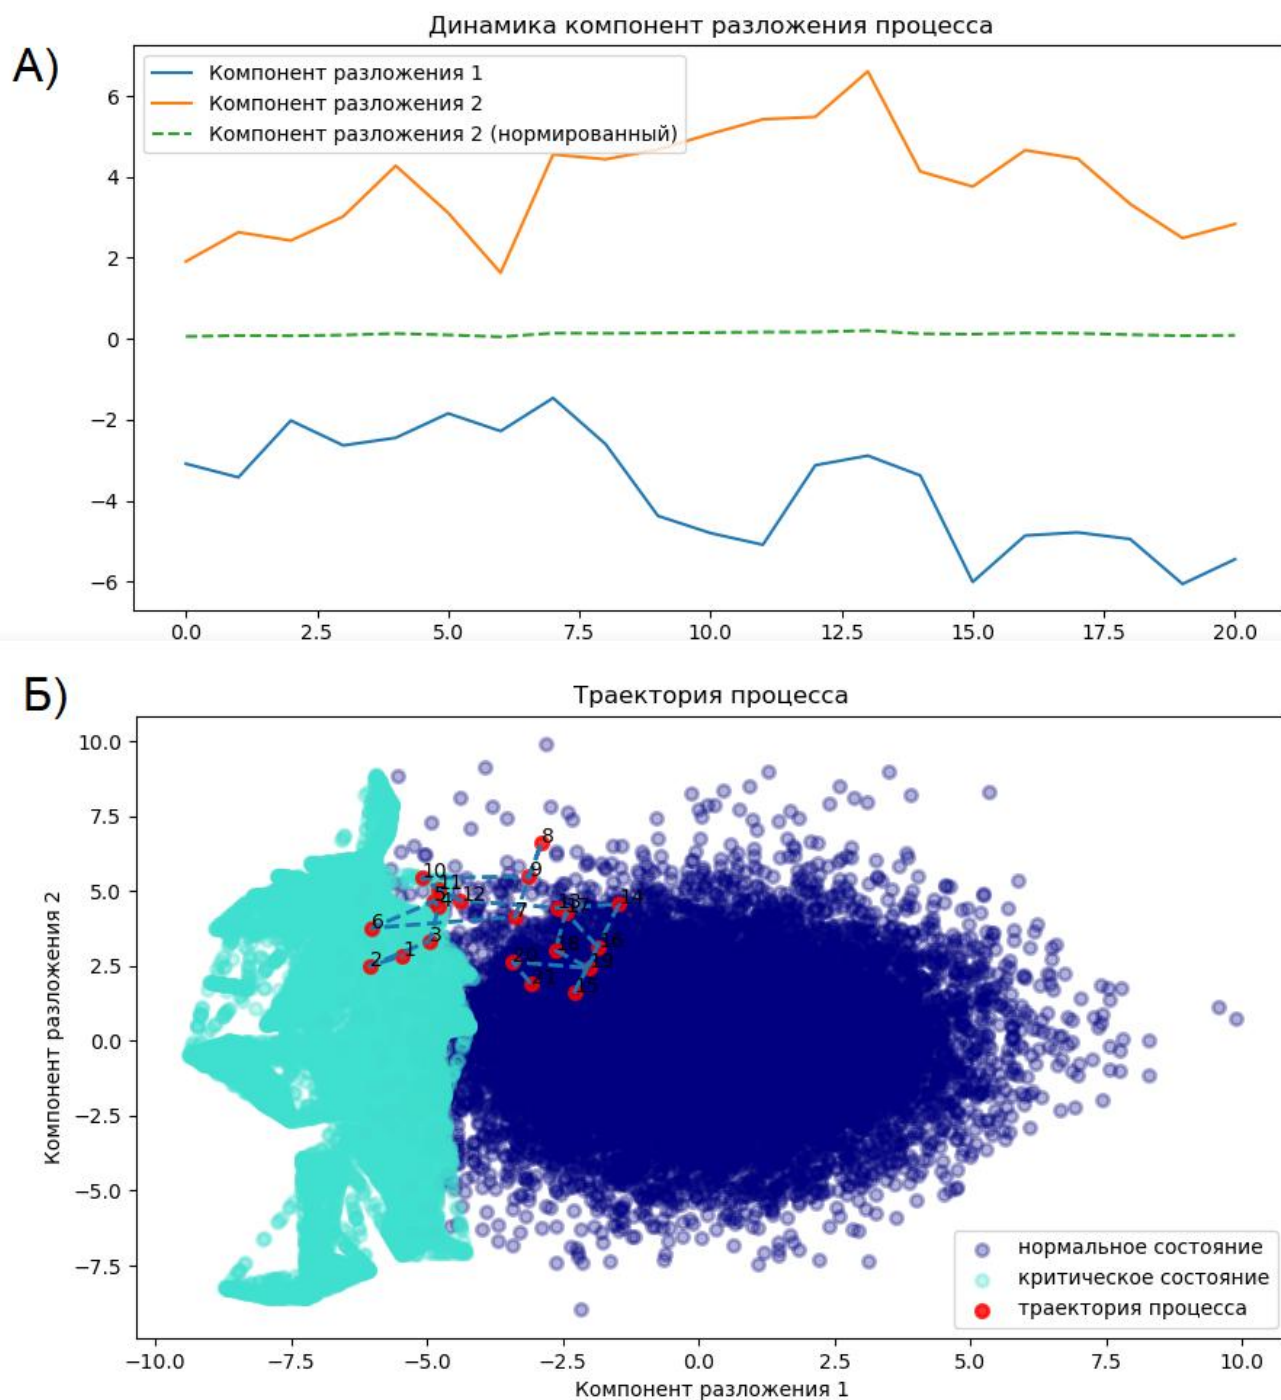


Рис. 2. – Динамика компонент разложения параметров мониторинга: (А) по времени, (Б) в фазовом пространстве самих компонент совокупно с историческими данными

Для удобства интерпретации расстояние лучше иметь в нормированном виде в диапазоне от 0 до 1, где 0 – максимально удаленное от зоны инцидентов значение, а 1 – максимально близкое.

Для расчета нормированного расстояния предлагается следующая методика. На первом этапе необходимо рассчитать среднее расстояние между всеми безопасными значениями параметров (точки метрического пространства), для которых ранее не наблюдалось инцидентов, и ближайшими K потенциально опасными сочетаниями параметров, для которых ранее уже наблюдались инциденты. Примером такого пространства является двумерное пространство компонентов разложения измеряемых параметров (см. рис. 2), однако в общем случае число компонент не ограничивается двумя, а подбирается экспериментально, максимизируя заданную метрику по всей цепочке вызова моделей. Расчет среднего расстояния между “безопасными” (обозначим, как множество X) и “опасными” (обозначим, как множество Y) точками пространства целесообразно осуществлять для ограниченной выборки, т.к. для больших временных рядов мониторинга, которые могут содержать сотни тысяч значений для десятков измеряемых параметров, операция может быть вычислительно слишком трудоемкой. В итоге среднее расстояние можно посчитать как:

$$\bar{d}_{xy} = \sum_{i=1 \dots N} \sum_{j=1 \dots K} \frac{d(x_i, y_j)_{\min}}{K \cdot N}, x \in X, y \in Y, \quad (1)$$

где N – количество “безопасных” точек пространства, а K – количество ближайших (индекс “min”) “опасных” точек пространства, которые отбираются для оценки близости зоны концентрации опасных значений с использованием дерева квадрантов. Значение K можно ограничить разумным значением, например 10, 20 или 50, в зависимости от зашумленности исходных данных. Для мало зашумленных данных, в которых опасная зона пространства параметров хорошо локализована, можно использовать меньшее значение. В приведенных примерах используется значение $K = 40$.

При практическом использовании для нормировки расстояния можно воспользоваться модифицированной формулой (1):

$$d_{x^*} = \sum_{j=1 \dots K} \frac{d(x^*, y_j)_{min}}{K}, y \in Y, \quad (2)$$

где x^* – это текущая точка (срез параметров) измерений. Однако полученное значение сложно интерпретировать, поэтому имеет смысл применить следующие модификации:

$$d_{x^*}^{norm} = \begin{cases} 0, & \text{если } d_{x^*} > \bar{d}_{xy} \\ \frac{\bar{d}_{xy} - d_{x^*}}{\bar{d}_{xy}}, & \text{если } d_{x^*} < \bar{d}_{xy} \end{cases}, \quad (3)$$

что позволяет получить нормированное значение расстояния, для которого можно установить универсальное пороговое значение, независящее от входных данных. Стоит заметить, что можно предложить и другие варианты расчета или нормировки расстояния. Главное требование к методу расчета расстояний – ясная интерпретация рассчитанных значений.

Экспериментальные исследования

Эксперименты проводились на 20 параметрах мониторинга с длиной реализации 40 тысяч элементов с разделением на обучающую и тестовую выборку в соотношении 1 к 5. Пример оценки заблаговременности, повышение которой является основной целью работы, показан на рисунке 3.

В указанном примере дополнительное использование метрического пространства позволило повысить заблаговременность выявления инцидента с 6 до 11 единиц времени. Заметим, что использование для классификации состояний исключительно близости к ранее наблюдаемым инцидентам будет приводить к дополнительным ложным срабатываниям, а использование исключительно вероятности к ложным отбоям. Таким образом, для обеспечения баланса точности и заблаговременности имеет смысл скомбинировать оба подхода.

На рисунке 3Б дополнительно показан вариант расчета расстояний без учета важности признаков в пространстве компонент разложения (зеленая пунктирная

линия), однако такой подход в большинстве случаев показывает результаты хуже, чем использование дополнительной нормировки на важность признаков. Такой результат в целом ожидаем, так как значительно менее важные признаки при расчете расстояний вводят дополнительный шум в результаты расчета, т.е. истинная близость двух точек пространства искажается.

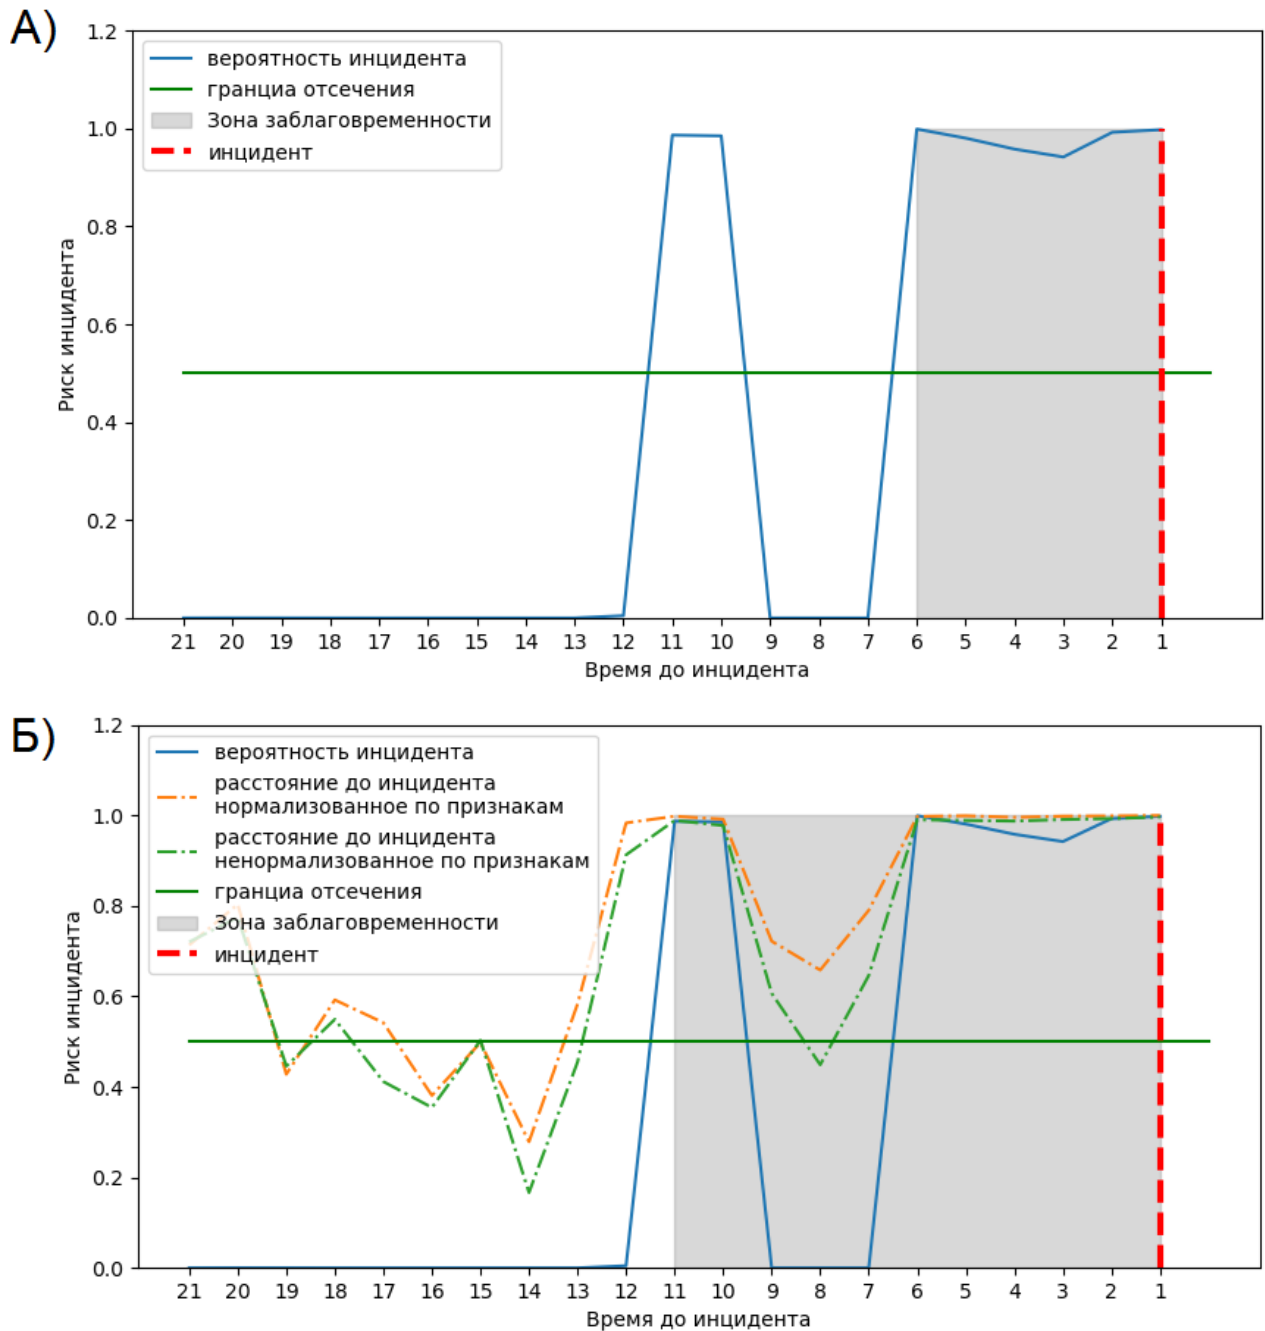


Рис. 3. – Пример оценки заблаговременности выявления инцидента: (А) на основе вероятности классификатора, (Б) на основе совокупного использования вероятности классификатора и расстояния до инцидентов в обучающей выборке

При расчете на всей тестовой выборке по результатам трех независимых экспериментов были получены следующие интегральные оценки качества системы мониторинга (см. таблицу №1).

Таблица № 1

Оценки качества системы мониторинга, полученные на тестовой выборке

<i>Эксперимент 1</i>	<i>Без расстояний</i>	<i>Расстояние без нормировки по важности признаков</i>	<i>Расстояние с нормировкой по важности признаков</i>
Заблаговременность	2.76	4.62	4.83
Точность (precision)	0.59	0.69	0.72
Полнота (recall)	0.81	0.85	0.87
<i>Эксперимент 2</i>			
Заблаговременность	4.23	6.42	7.06
Точность (precision)	0.64	0.78	0.8
Полнота (recall)	0.96	0.96	0.96
<i>Эксперимент 3</i>			
Заблаговременность	1.38	1.83	2.94
Точность (precision)	0.65	0.76	0.76
Полнота (recall)	0.86	0.86	0.86

Дополнительное использование метрических пространств примерно вдвое повышает заблаговременность выявления инцидентов, повышая при этом показатели точности и полноты. Обратим внимание, что использование дополнительной нормировки по важности признаков (feature importance) для компонентов вектора при расчете расстояний также улучшает рассчитанные метрики качества.

В плане оценки применимости предложенного подхода следует сделать акцент на скорости изменения самих параметров мониторинга. В тех случаях, когда параметры мониторинга изменяются скачкообразно, речи о возможности выявлять инциденты заранее не идет. Для оценки скорости изменения параметров можно использовать корреляционные функции или анализировать

авторегрессионные коэффициенты временных рядов исследуемых параметров. Если первые два коэффициента авторегрессии превышают значение 0.8, то с большой вероятностью можно обеспечить разумную заблаговременность в изменениях параметров технической системы.

Отдельно стоит отметить потенциальную полезность предложенного подхода для систем с большим числом параметров (несколько десятков или даже сотен), визуальное отслеживание которых оператором принципиально невозможно. Данный эффект достигается в первую очередь за счет применения различных подходов к снижению размерности исходных данных.

Заключение

В работе рассмотрен подход, позволяющий повысить эффективность использования моделей машинного обучения в задачах мониторинга за счет использования метрических пространств.

Для решения задачи предложен способ оценки качества систем мониторинга на основе интервальных оценок зон необходимой реакции на возможный инцидент.

Расчет границ интервала основан на вероятностях, получаемых с помощью классификатора, обученного выявлять опасные состояния системы. Совокупное использование вероятности инцидента и нормированного расстояния до инцидентов в обучающей выборке позволяет повысить одновременно все рассмотренные метрики качества мониторинга – точность, полноту и заблаговременность.

Предложенный подход носит универсальный характер и может применяться для различных алгоритмов классификации и способов расчета расстояний.

Литература

1. Гаглыева И. Э., Добаев А. З., Дедегкаева А. А. Разработка математической модели комплексной оценки состояния электроэнергетических объектов //

Инженерный вестник Дона, 2013, №. 3 URL:
ivdon.ru/ru/magazine/archive/n3y2013/1842/.

2. Carvalho T. P., Soares F. A. A. M. N., Vita R., Francisco R. da P., Basto J. P., Alcala S. G. S. A systematic literature review of machine learning methods applied to predictive maintenance //Computers & Industrial Engineering. – 2019. – V. 137. – P. 106024.

3. Carbone R., Armstrong J. S. Note. Evaluation of extrapolative forecasting methods: results of a survey of academicians and practitioners //Journal of Forecasting. – 1982. – V. 1. – №. 2. – pp. 215-217.

4. Kovács G., Sebestyén G., Hangan A. Evaluation metrics for anomaly detection algorithms in time-series //Acta Universitatis Sapientiae, Informatica. – 2019. – V. 11. – №. 2. – pp. 113-130.

5. Esmael B., Arnaout A., Fruhwirth R. K., Thonhauser G. Improving time series classification using Hidden Markov Models //2012 12th International Conference on Hybrid Intelligent Systems (HIS). – IEEE, 2012. – pp. 502-507.

6. Gensler A., Sick B. Novel Criteria to Measure Performance of Time Series Segmentation Techniques //LWA. – 2014. – pp. 193-204.

7. Metzger A., Kley T., Rothweiler A., Pohl K. Automatically reconciling the trade-off between prediction accuracy and earliness in prescriptive business process monitoring //Information Systems. – 2023. – V. 118. – P. 102254.

8. Dion R., Alamir M., Le Magueresse T. Anticipation, earliness, alarm cardinality: A new metric for industrial time-series anomaly detection // IFAC-PapersOnLine. - 2024. – V. 58. №4. - pp. 192-197.

9. Ray P., Reddy S. S., Banerjee T. Various dimension reduction techniques for high dimensional data analysis: a review //Artificial Intelligence Review. – 2021. – V. 54. – №. 5. – pp. 3473-3515.

10. Mori U., Mendiburu A., Dasgupta S., Lozano J. A. Early classification of time series by simultaneously optimizing the accuracy and earliness //IEEE transactions on neural networks and learning systems. – 2017. – V. 29. – №. 10. – pp. 4569-4578.

11. Большаков М. А. Подготовка данных системы мониторинга ИТ-инфраструктуры для моделей выявления критических состояний на основе нейросетей // Научные технологии в космических исследованиях Земли. – 2019. – Т. 11, № 4. – С. 65-71. – DOI: 10.24411/2409-5419-2018-10280. – EDN GGSIBE.

12. Горлатов Д. В. Машинное обучение прогнозных моделей на несбалансированных данных по опасным астероидам // Инженерный вестник Дона, 2023, №. 5 URL: ivdon.ru/ru/magazine/archive/n5y2023/8394/

References

1. Gagloeva I. E., Dobaev A. Z., Dedegkaeva A. A. Inzhenernyj vestnik Dona, 2013, №. 3. URL: ivdon.ru/ru/magazine/archive/n3y2013/1842/.

2. Carvalho T. P., Soares F. A. A. M. N., Vita R., Francisco R. da P., Basto J. P., Alcala S. G. S. Computers & Industrial Engineering. 2019. V. 137. P. 106024.

3. Carbone R., Armstrong J. S. Note. Journal of Forecasting. 1982. V. 1. №. 2. pp. 215-217.

4. Kovács G., Sebestyén G., Hangan A. Acta Universitatis Sapientiae, Informatica. 2019. V. 11. №. 2. pp. 113-130.

5. Esmael B., Arnaout A., Fruhwirth R. K., Thonhauser G. 2012 12th International Conference on Hybrid Intelligent Systems (HIS). IEEE, 2012. pp. 502-507.

6. Gensler A., Sick B. LWA. 2014. pp. 193-204.

7. Metzger A., Kley T., Rothweiler A., Pohl K. Information Systems. 2023. V. 118. P. 102254.

8. Dion R., Alamir M., Le Magueresse T. IFAC-PapersOnLine. 2024. V. 58. №4. pp. 192-197.

9. Ray P., Reddy S. S., Banerjee T. Artificial Intelligence Review. 2021. V. 54. №. 5. pp. 3473-3515.

10. Mori U., Mendiburu A., Dasgupta S., Lozano J. A. IEEE transactions on neural networks and learning systems. 2017. V. 29. №. 10. pp. 4569-4578.



11. Bolshakov M. A. Naukoemkie tekhnologii v kosmicheskikh issledovaniyakh Zemli. 2019. V. 11, № 4. pp. 65-71. DOI: 10.24411/2409-5419-2018-10280. EDN GGSIBE.

12. Gorlatov D. V. Inzhenernyj vestnik Dona, 2023, №. 5. URL: vdon.ru/ru/magazine/archive/n5y2023/8394/.

Дата поступления: 7.10.2024

Дата публикации: 24.11.2024