

© 2021 г. П.А. МУХАЧЁВ (petr.mukhachev@skoltech.ru),
Т.Р. САДРЕТДИНОВ (tagir.sadretdinov@skoltech.ru),
Д.А. ПРИТЫКИН, канд. физ.-мат. наук (d.pritykin@skoltech.ru),
А.Б. ИВАНОВ, д-р философии (anton.ivanov2@skoltech.ru)
(Сколковский институт науки и технологий, Москва),
С.В. СОЛОВЬЕВ, канд. техн. наук (sergey.soloviev@scsc.ru)
(Публичное акционерное общество “Ракетно-космическая корпорация “Энергия”,
Королев, Московская обл.)

СОВРЕМЕННЫЕ МЕТОДЫ МАШИННОГО ОБУЧЕНИЯ ДЛЯ АНАЛИЗА ТЕХНИЧЕСКОГО СОСТОЯНИЯ КОСМИЧЕСКИХ АППАРАТОВ ПО ДАННЫМ ТЕЛЕМЕТРИЧЕСКОЙ ИНФОРМАЦИИ

Приводится обзор основных достижений в области методов интеллектуального анализа данных о техническом состоянии космических аппаратов (КА). Основной акцент делается на анализе телеметрической информации (ТМИ), позволяющем идентифицировать нехарактерные для нормальной работы состояния КА и предсказывать возможные сбои в работе КА или его составных частей. Рассмотрены основные этапы, необходимые для создания систем мониторинга состояния КА общего назначения, подробно представлены методы обнаружения аномалий в ТМИ с учетом специфики КА и проанализированы известные авторам публикации по этой тематике. Приведены примеры внедрения таких систем в центрах управления полетами разных стран. Обсуждаются перспективные направления развития методов анализа технического состояния сложных систем, которые актуальны для решения задач в космической технике, а также отмечаются основные факторы, препятствующие развитию методов машинного обучения для анализа телеметрической информации.

Ключевые слова: интеллектуальный анализ данных, поиск аномалий, управление полетом, техническая диагностика, телеметрическая информация.

DOI: 10.31857/S0005231021080018

1. Введение

Космические аппараты (КА) и их составные части проектируются с учетом большого количества факторов: выполняемой программы полета, внешней среды, других систем, с которыми предстоит взаимодействие, и возможных управляющих воздействий. Однако неизбежные погрешности проектирования, моделирования и верификации не позволяют создать точные модели каждой из составных частей и КА в целом, и всех его возможных отказов в реальном космическом полете. Таким образом, во время функционирования КА могут возникать различного рода непредвиденные ситуации, приводящие к сбоям в работе составных частей КА, и ситуации, не просчитывавшиеся при создании КА и планировании программы полета.

Общий подход к обнаружению, локализации и устранению неисправностей (fault detection, isolation and recovery FDIR) призван обеспечить бесперебойное выполнение функций КА [1]. Этот подход предполагает обеспечение резервирования, применение систем автоматического управления, осуществляющих диагностику и запускающих процедуры восстановления, а также

тщательное изучение выявленных отказов, непредвиденных ситуаций и соответствующую корректировку программы полета.

В работах [2, 3] отмечается, что в настоящее время основными способами контроля технического состояния КА являются мониторинг пороговых значений и постоянный контроль ключевых телеметрических параметров (ТМП) оператором [2, 3]. Однако время специалиста дорого, а в его поле зрения могут постоянно находиться лишь несколько ТМП. В то же время число ТМП в КА часто достигает нескольких тысяч, к примеру космический аппарат GOCE имел 1300 ТМП, а в более крупных КА число ТМП может доходить до 50 тысяч [4], что делает невозможным ручной контроль параметров оператором. Мониторинг пороговых значений, вообще говоря, не позволяет обнаружить приближение нештатной ситуации (НШС) или выделить нехарактерное поведение КА. С развитием проектов по развертыванию мега-группировок автоматизация и интеллектуализация процесса мониторинга технического состояния спутников становятся еще более актуальными [5, 6].

Как показывает практика, нехарактерное поведение значений ТМП представляет интерес, поскольку часто предшествует сбоям в работе тех или иных составных частей КА. Такое anomальное поведение обычно не детектируется стандартными методами мониторинга пороговых значений. Задача поиска аномалий в телеметрической информации (ТМИ) очень сложна. Как правило, об аномалиях не хватает исторической информации, а появление аномалий не всегда предвещает отказ. Аномалии могут быть вызваны случайными сбоями в работе датчиков или канала передачи информации, нехарактерными ситуациями как безвредными, так и потенциально опасными для работы КА; они не имеют четкой границы, номинальное состояние может эволюционировать в процессе эксплуатации КА, а понятие аномалии будет отличаться для разных составных частей. Тем не менее задача обнаружения аномалий в ТМИ важна для последующей диагностики и анализа функционирования КА.

Для обнаружения аномалий используют два основных подхода. Первый предполагает наличие модели, которая явным количественным образом описывает работу системы. В этом случае несоответствие поведения системы и модели может служить индикатором неисправности. С одной стороны, такой подход позволяет явным образом моделировать неисправности и их последствия, с другой стороны, очевидным недостатком является сложность создания лежащих в его основе моделей. Второй подход заключается в применении методов машинного обучения, с помощью которых можно создавать модели работы системы на основе имеющихся данных. В [3, 6] подчеркивается важность развития таких систем для анализа технического состояния КА [3, 6]. В случае когда база данных обширна, на основе таких моделей могут быть созданы экспертные системы для диагностики КА. Обзору последних достижений в области применения методов машинного обучения для анализа состояния КА и посвящена настоящая статья.

Автоматизации обнаружения аномалий в данных из различных областей в последнее время было посвящено множество обзорных публикаций, освещающих как общие, так и более узкие тематики. Среди них можно выделить Chandola [7], Pimentel [8] и Wang [9], которые группируют методы по основным предположениям о природе анализируемых данных, дают оценки вычислительной сложности применяемых алгоритмов и перечисляют основные их

практические приложения. Chalapathy и соавт. [10] подробнее рассматривают методы, основанные на применении искусственных нейронных сетей и глубокого обучения. Zimek [11] и Thudumu [12] обсуждают особенности анализа данных с очень большой размерностью. Gavrilovski [13], Khan и Yairi [14], Basora [15] сделали обзоры по применениям методов поиска аномалий, в том числе в авиационной отрасли.

Несмотря на наличие перечисленных выше публикаций, насколько известно авторам настоящей статьи, на данный момент не существует обзора, раскрывающего современное состояние методов интеллектуального анализа данных космической техники. Настоящий обзор заполняет этот пробел, учитывает специфику, связанную именно с космической техникой, и возможные методы анализа ТМИ, выделяя направления, необходимые для дальнейшего развития и обозначая наиболее перспективные методы.

Обзор состоит из восьми разделов. В разделе 2 описаны основные используемые определения и постановки задачи с точки зрения анализа данных. Различные методы выделения признаков для улучшения работы алгоритмов обсуждаются в разделе 3. Раздел 4 посвящен классификации методов обнаружения аномалий и основным примерам их использования. Раздел 5 обсуждает, каким образом принимаются решения об отнесении некоторого состояния системы к аномальным, если используемые методы анализа данных не классифицируют состояния, а отображают их на непрерывный интервал числовой оси. В разделе 6 описаны методы определения качества работы алгоритмов, основанных на данных. В разделе 7 обсуждаются применения систем, основанных на данных, в различных центрах управления полетами на постоянной основе, перечислены открытые источники данных, на которых возможно проверять работу некоторых алгоритмов, а также обсуждаются перспективные методы анализа данных. Наконец, в разделе 8 кратко сформулированы основные результаты данной статьи.

2. Основные понятия

2.1. Аномалии и выбросы в телеметрической информации

В литературе термины *выброс* (outlier) и аномалия часто употребляются в одном значении, и четкого разграничения не существует, поскольку исследователи из разных областей используют разную терминологию. Тем не менее, как отметил Pimentel [8], выбросами часто называют малую часть нормальных данных, которые лежат далеко от большинства по-настоящему нормальных данных. Таким образом, поиск выбросов сосредоточен на выделении именно таких данных, которые могут существенно ухудшать работу некоторых алгоритмов.

Некоторые исследователи используют термин “*новая информация*” (novelty) для обозначения данных, которые не соответствуют модели, построенной с использованием данных, априори считающихся нормальными. В этот класс уже не будут входить случайные выбросы, о которых изложено в предыдущем абзаце, если они присутствуют в модели “нормальных” данных.

В [7] аномалии подразделяются на точечные, контекстные и коллективные. Точечные аномалии характеризуются выбросом единственного экземпляра из своего окружения и являются самыми простыми для обнаружения. Контекстные аномалии представляют собой ситуации, появление которых зависит от




Рис. 1. Типы аномалий: 1 — точечная, 2 — контекстная, 3 — коллективная.

некоторого внешнего контекста или других переменных, без учета которых они не будут считаться аномальными. Коллективные аномалии характерны для временных рядов или других упорядоченных данных. Они имеют место, если несколько ближайших точек образуют аномальное поведение, но не могут считаться аномальными по отдельности (рис. 1).

Телеметрическая информация (ТМИ) представляет собой показания бортовых датчиков КА и программные события, циркулирующие в контуре управления и передаваемые на землю. Общая структура потоков информации в контуре управления космическим аппаратом приведена в [16]. Показания датчиков чаще всего структурируются во временные ряды, которые могут быть неравномерными (или неэквидистантными), т.е. с переменным шагом по времени, причем шаг может быть различным для разных телеметрических параметров (ТМП). ТМИ является основным источником информации о состоянии КА и в этом смысле ТМИ наиболее полна и достоверна. На основании анализа ТМИ делаются заключения о техническом состоянии КА и его составных частей и принимаются решения о планировании дальнейшего полета. Далее сосредоточимся на анализе ТМИ, представленной в виде многомерных временных рядов, и опустим рассуждения об анализе программных событий.

ТМИ принимается и обрабатывается системой мониторинга, реализованной бортовыми и наземными системами. Эта система реализует различные алгоритмы для извлечения полезной информации о состоянии КА и, при необходимости, последующего совершения корректирующего воздействия или оповещения оператора для принятия решения о таком воздействии.

2.2. Возможные постановки

Можно выделить следующие крупные классы алгоритмов для анализа состояния технических систем: основанные на данных и основанные на моделях. Алгоритмы, основанные на моделях, характеризуются тем, что они требуют наличия заранее созданной разработчиком явной схемы и, в отличие от алгоритмов, основанных на данных, не имеют широкой возможности к адаптации на основе исторической информации о работе системы [17]. Алгоритмы, основанные на данных, в свою очередь требуют достаточно большого корпуса исторической информации для подбора коэффициентов модели (обучения) и валидации правильности ее работы.

В общем виде задачу технической диагностики можно поставить следующим образом. Для краткости введем обозначения: $Z(t)|t = t_0$ — состояние системы в определенный момент времени, $Y = y(Z(t))$ — некоторый дискретный

набор классов оценки качества работы системы либо такая оценка по непрерывной шкале, $X(t) = f(Z(t)) + \xi$ – набор видимых наблюдений показаний различных датчиков. Как правило, функция f известна с некоторой точностью в соответствии со спецификацией рассматриваемого датчика, однако это не всегда так. Вектор ξ представляет собой набор остаточных ошибок измерения. Общая постановка заключается в восстановлении значения Y по X , т.е. в нахождении как можно более точной аппроксимации некоторой функции $g : Y = g(X)$. Функция f не всегда обратима, а ошибки ξ не всегда могут быть точно описаны, поэтому в общем виде задача не имеет строгого решения.

Далее подробно обсудим методы, основанные на данных. Они имеют большое практическое значение, поскольку применимы к системам, в которых формальное описание работы представляет существенные трудности. Постановки задачи машинного обучения в самом общем виде можно сформулировать так [18]:

– обучение с учителем или контролируемое обучение. Пусть известна некоторая обучающая выборка $D = \{(x^n, y^n), n = 1, \dots, N\}$. Задача заключается в восстановлении функции f , такой что предсказание $f(x^*) = y^*$ будет точным на новом экземпляре (x^*, y^*) из тестовой выборки. При этом критерий точности определяется заданной функцией ошибок;

– обучение без учителя или неконтролируемое обучение. Пусть дан некоторый корпус данных $D = \{x^n, n = 1, \dots, N\}$. Задача стоит в том, чтобы описать эти данные некоторым более компактным образом, который определяется некоторой целевой функцией.

Совокупность обучающей и тестовой выборок называют корпусом данных (dataset). Совокупность векторов y^n называют разметкой. Задача обучения с учителем будет называться классификацией, если область значений y^n дискретна, и регрессией, если область значений y^n непрерывна.

Поскольку на практике истинное состояние КА часто не поддается непосредственному наблюдению, обычно предполагается, что показания датчиков достаточно точно определяют состояние, и задачи мониторинга технического состояния сводятся к следующим постановкам:

1) классификация состояний и их последовательностей. В этом случае $Y \in \mathbb{N}$ дискретна и имеется некоторое количество наблюдений $Y = g(Z(t_i))$;

2) выделение аномалий. В этой постановке $Y = \{0, 1\}$ и известны наблюдения только одного из двух классов $Z : g(Z) = 0$;

3) поиск выбросов. При этом необходимо оценить значение $g(Z)$ на основании только наблюдений X при отсутствии наблюдений Y ;

4) ранжирование результатов по важности (степени аномальности), также называемое скоринг. Эта задача характеризуется непрерывной областью значений $Y \in \mathbb{R}$;

5) прогноз состояния КА: нахождение значений ТМП $X(t_1 + n)$, оценки качества работы $Y = y(X(t_1 + n))$ или непосредственно состояния системы $Z(t_1 + n)$ на основании истории значений ТМП $\{X(t) : t_0 \leq t \leq t_1\}$;

6) оценка остаточного ресурса КА или его частей аналогична предыдущей постановке, однако в этом случае, как правило, представляет интерес более долгосрочный прогноз.

В задаче поиска выбросов алгоритму дается неразмеченный корпус данных, среди которых требуется выделить маловероятные состояния или их последовательности, т.е. эта постановка является задачей обучения без учителя. Однако при поиске аномалий эти методы могут давать большую долю ложных положительных и ложных отрицательных результатов, поскольку не каждая аномалия представляет из себя выброс и не каждый выброс можно считать аномалией. В [7, 8] отмечается, что эта постановка в основном применяется для избавления от случайных редких шумов и выбросов, поскольку при этом исходные данные содержат в себе очень мало информации о правильности функционирования КА.

При поиске аномалий эта постановка может применяться для локализации найденной аномалии или для предоставления оператору более подробной информации о штатном функционировании КА. Как правило, в этой постановке используются методы контролируемого обучения (или, что то же самое, обучение с учителем). Контролируемое обучение заключается в нахождении аппроксимации неизвестной функции по набору ее наблюдаемых значений. Задача классификации в этом случае представляет собой нахождение функции с дискретной областью значений.

В задаче классификации обучающая выборка X состоит из предварительно размеченных данных: каждое состояние или ситуация X_i принадлежит одному или нескольким из отдельных классов Y_i . В процессе работы алгоритм относит каждую новую ситуацию к тому классу, которому она принадлежит с наибольшей вероятностью.

При поиске аномалий обучающая выборка, как правило, состоит только из представителей одного класса — нормальной работы системы. В некоторых постановках в обучающей выборке может находиться сравнительно малое количество представителей аномальной работы. При работе алгоритм выделяет ситуации, которые не похожи на те, что встречались в обучающей выборке.

Кроме того, начинают появляться алгоритмы, способные к активному обучению. Эти алгоритмы обучаются в полуконтролируемом режиме, т.е. когда разметка данных доступна не для всех X_i , и способны запросить у пользователя разметку, когда это необходимо [19, 20]. Такие алгоритмы подходят для очень больших баз данных, когда полная ручная разметка при создании корпуса данных невозможна. Этот класс алгоритмов появился сравнительно недавно и требует дальнейшего изучения.

2.3. Основные этапы анализа телеметрической информации

Несмотря на последние успехи в создании математического аппарата и алгоритмов интеллектуального анализа данных, человек все еще должен выбрать алгоритм и адаптировать его под стоящую перед ним задачу и ее особенности. Методология ASUM-DM [21] выделяет шесть основных этапов проекта по работе с данными: анализ предметной области, разработка, создание и настройка рабочей модели, ввод в эксплуатацию, эксплуатация и оптимизация, управление проектом.

При создании рабочей модели и настройке ее параметров важно знать объективное качество ее работы по сравнению с другими моделями и оператором. Для оценки качества требуется эталонная разметка данных, которая



Рис. 2. Основные этапы анализа ТМИ.

часто отсутствует в реальных задачах. Обычно при отсутствии объективного критерия качества работы модели или алгоритма, основанного на данных, обоснование правильности его работы носит спекулятивный характер. Этот феноменологический принцип верификации в корне отличается от верификации модельно-ориентированных систем, где правильность работы показывается верностью изначальных предположений и логических умозаключений.

На этапе эксплуатации системы мониторинга (рис. 2) анализу обычно предшествуют выделение и, при наличии механизмов, восстановление достоверной ТМИ (отсеивание случайных выбросов) и изменение частоты дискретизации, для чего необходимо знание о характеристиках датчика и природе измеряемой величины. После этого производится анализ с использованием различных алгоритмов, речь о которых пойдет далее. Анализ также можно разделить на несколько этапов:

- 1) формирование набора параметров (признаков), с которыми непосредственно будет работать алгоритм интеллектуального анализа данных;
- 2) построение или уточнение модели;
- 3) ее применение для получения результата.

Выделение признаков может происходить как силами экспертов, так и автоматически, однако для автоматического выделения признаков, как правило, требуется большой объем обучающих данных, а построенную модель сложнее интерпретировать. В этом случае этап выделения признаков не выражен явно, так как происходит во время построения и применения алгоритмов. Так, например, происходит в случае использования глубоких нейронных сетей.

Последним этапом производится постобработка результатов анализа для формирования отчетов и их вывода на экран оператора.

3. Формирование набора параметров для анализа

В контексте задач машинного обучения любые измеримые или вычислимые характеристики объекта исследования, которые каким-либо образом помогают в решении задачи, принято называть признаками. Например, при определении текущего состояния КА признаками могут считаться значения ТМП, параметры космической погоды и т.п. В сложных задачах бывает важно выделить вспомогательные признаки, которые являются некоторой функцией исходных и помогают улучшить результат и/или уменьшить вычислительную сложность. При автоматическом выделении признаков, как это происходит при применении глубоких нейронных сетей, признаки могут быть лишены конкретного физического смысла и являться только математической функцией исходных данных.

Выделение признаков не является самостоятельным способом поиска аномалий или определения технического состояния КА, но имеет большое значение, особенно при анализе многомерных временных рядов в сложных системах, где встречается большое количество как взаимосвязанных ТМП и резервированных датчиков, так и ТМП, которые не имеют отношения к выделению тех или иных типов аномалий, вносят шумы и затрудняют их поиск. Правильное выделение признаков из исходных данных может значительно облегчить задачу поиска аномалий, улучшить показатели работы алгоритма и его интерпретируемость. В большинстве случаев выбор ТМП, по которым будет осуществляться контроль состояния, происходит при помощи эксперта.

Suo и соавт. в [22] ввели понятие нечеткого Байесовского риска для выбора подмножества переменных для дальнейшей классификации. В [22] показано, что при использовании функции потерь определенного вида возможно построить жадный алгоритм для выбора подпространства, в котором отделение классов друг от друга будет оптимальным с точки зрения этой метрики. Вычислительная сложность алгоритма составила $O(knm^2)$, где k — число выбранных ТМП, n — число классов, m — число точек. В [22] были использованы разменные результаты численного моделирования системы энергоснабжения (СЭП) для демонстрации работы алгоритма и сравнения с алгоритмами ReliefF [23], mRMR [24], NRS [25] и другими.

Для анализа периодических сигналов, особенно высокочастотных, в качестве представления сигнала часто используют дискретное преобразование Фурье, вейвлет-преобразования [26]. При анализе многомерных временных рядов большое значение имеют техники понижения размерности, такие как метод главных компонент, факторный анализ, а также экспертный выбор и создание информативных признаков, поскольку они могут значительно уменьшить вычислительные ресурсы, необходимые для проведения анализа.

Масштабная работа по исследованию качества выделения аномалий в зависимости от выбранных признаков на одномерных временных рядах была проведена Vargeure в [27]. Авторы настоящей статьи исследовали признаки, выделенные с помощью преобразования Фурье, вейвлет-преобразований, собственных функций Гауссова ядра, метода главных компонент, периодограмм, и методы выявления аномалий, основанные на расстоянии и локальной плотности (подраздел 4.1), а также метод опорных векторов (подраздел 4.4). В [27] использованы искусственно сгенерированные данные, а также реальные данные для валидации результатов (1700 ТМП, собранных более чем за 12 лет). В статье приведены практические выводы об используемых методах и признаках.

С другой стороны, O’Meara и Schlag [28] показали, что использование признаков, заданных вручную с учетом физики наблюдаемого процесса, способно значительно улучшить качество предсказаний и поиска аномалий. К тому же выводу приходит Gowda в [29]: “Выделение признаков является практически решающим фактором. Оно имеет большее значение, чем использование тех или иных моделей машинного обучения” — пишет он. Gowda использовал данные ТМИ Mars Express [30] для построения предсказательной модели потребления системы обеспечения теплового режима (СОТР).

4. Методы анализа телеметрической информации и примеры их применения

Многие публикации [7, 8, 15] выделяют следующие типы алгоритмов, которые основаны на базовых предположениях о нормальных и аномальных данных:

- 1) основанные на расстоянии:
 - а) основанные на анализе графа соседства,
 - б) основанные на кластеризации;
- 2) статистические:
 - а) параметрические:
 - смесь распределений,
 - стохастические процессы;
 - б) непараметрические;
- 3) классификационные,
- 4) основанные на реконструкции,
- 5) ансамблевые.

На рис. 3 изображены классификация и типичные представители классов алгоритмов. Отметим, что несмотря на то что представленная классификация включает многие алгоритмы, она не может считаться полной и учитывающей все аспекты существующих алгоритмов.

Большая часть этих методов специально не приспособлена для анализа временных рядов, однако может быть адаптирована соответствующим выбором признаков или применена к отдельным состояниям без использования последовательной структуры временного ряда.

Кроме того, во многих системах не все ТМП несут полезную информацию для поиска определенных типов отказов. Например, ТМП одной из составных частей КА будут нести мало информации о работоспособности другой. Поэтому для уменьшения потенциально затрачиваемых ресурсов и увеличения точности поиска могут применяться различные техники выбора признаков (см. раздел 3).

При выборе алгоритма и его параметров необходимо пользоваться объективными критериями оценки качества алгоритмов, а также сравнивать качество алгоритмов с качеством работы оператора (см. раздел 6).

Для удобства рассмотренные статьи собраны в Приложении.

4.1. Методы на основе анализа графа соседства

Методы, основанные на ближайших соседях, исходят из гипотезы о том, что точки, характеризующие нормальные состояния, располагаются близко друг к другу, в то время как аномальные данные находятся далеко от нормальных в некотором пространстве признаков. Изначально в качестве степени аномальности использовалось расстояние до K -го ближайшего соседа. Методы этой группы отличаются друг от друга тем, что они определяют понятие соседства разными способами.

Ву и Schwabacher в [31] предложили метод ORCA, показав, что в некоторых случаях частичным отсеканием поиска можно оптимизировать метод ближайших соседей до почти линейного масштабирования.

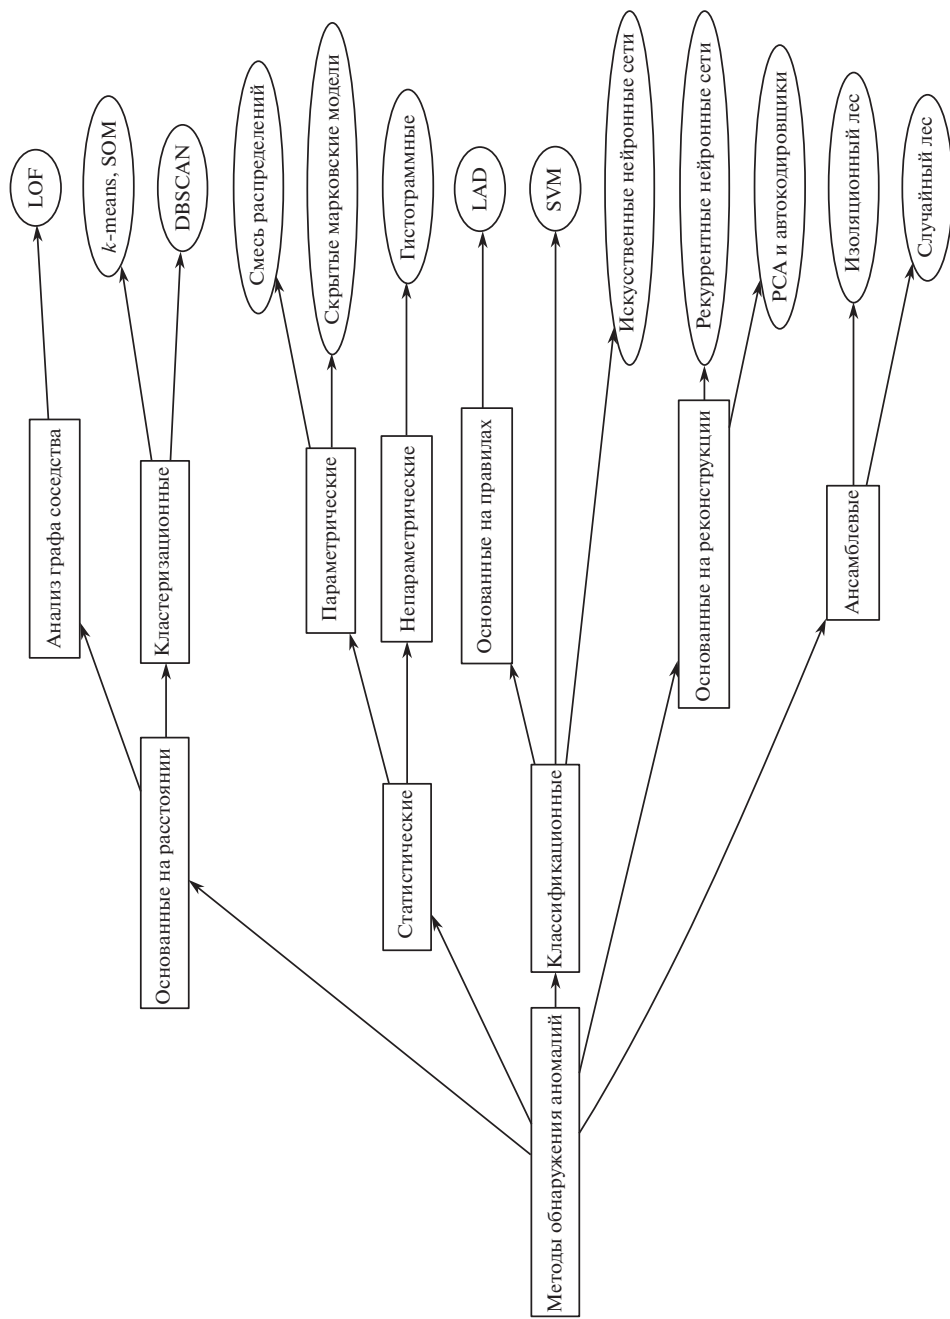


Рис. 3. Классификация алгоритмов, применяющихся для поиска аномалий и некоторые примеры соответствующих классов.

К этому классу можно отнести и методы, которые используют локальную плотность точек. Метод локального уровня выброса (Local Outlier Factor, LOF) [32] основан на вычислении локальной плотности вокруг точки и вокруг ее соседей:

$$LOF_{kNN}(p) = \left(\frac{\sum_{o \in kNN(p)} \frac{lrd_{kNN}(o)}{lrd_{kNN}(p)}}{|N_{kNN}(p)|} \right)^{-1}.$$

Значение LOF представляет собой обратную локальную доступную плотность точки по отношению к средней локальной доступной плотности ее соседей, где локальная доступная плотность (local reachability density)

$$lrd_{kNN}(p) = \frac{|N_{kNN}(p)|}{\sum_{o \in kNN(p)} RD_{kNN}(p, o)}$$

обратна среднему расстоянию доступности $RD_k(p, o) = \max(d_k(o), d(p, o))$ точки по k ее ближайших соседей. Отметим, что $N_{kNN}(p)$ может быть больше k , если есть несколько точек, равноудаленных от точки p .

Значение $LOF_{kNN}(p)$ можно интерпретировать как изолированность рассматриваемой точки p по сравнению с изолированностью k своих ближайших соседей. Для этого метода необходимо эмпирически задать число ближайших точек, которые считаются соседями рассматриваемой. Метод LOCI (local correlation integral) работает похожим образом и частично решает проблему ручного задания числа соседей, заменяя этот параметр расстоянием, точки внутри которого считаются соседями. Отношение k -го соседства в общем случае не является симметричным, поэтому многие методы используют отношения обратного и симметричного соседства для определения выбросов.

Von Brunken в [33] переработал метод LOF, предложив использовать локальную оценку естественной размерности данных (Intrinsic Dimension) [34, 35] в качестве оценки плотности. Новый метод был назван IDOS (Intrinsic Dimension Outlier Score) и показал очень хорошие результаты по сравнению с другими современными методами: LOF, SOD [36] и FastABOD [37] – на различных корпусах данных, при этом требуя меньших вычислительных ресурсов.

Некоторые алгоритмы также используют ядерные методы для оценки плотности [38], как это происходит в статистических методах для оценки плотности распределения. Например, одна из последних публикаций [39] предлагает оценивать степень выброшенности точки с использованием ядерной оценки плотности вероятности на основе соседей рассматриваемой точки.

Чаще всего для этих методов выбирают евклидово расстояние в некотором пространстве признаков. Однако существуют и другие варианты выбора расстояния, например, манхэттенское расстояние, или, что то же самое, метрика L_1 , или расстояние динамического преобразования временной шкалы (dynamic time warping, DTW) [40] в случае сравнения временных рядов.

Преимущества методов на основе анализа графа соседства:

– работу этих методов сравнительно просто интерпретировать;

— многие алгоритмы работают без учителя и могут быть адаптированы под полуконтролируемое обучение;

— их просто адаптировать под новые типы данных: для этого достаточно задать на них метрику;

— некоторые модификации хорошо масштабируются по времени, необходимому на вычисления на пространство большой размерности.

Недостатки методов на основе анализа графа соседства:

— эти алгоритмы опираются на метрику, поэтому может быть сложно иметь дело с категориальными переменными и сложными типами данных, например графами;

— они плохо масштабируются на большие объемы данных;

— сложно адаптировать к временным рядам;

— многие методы опираются на расстояние, поэтому их эффективность снижается на пространстве большой размерности;

— если у аномальных точек много соседей любого типа, получим ложно-положительный результат.

Главным недостатком этих методов является необходимость составления графа соседства, которое требует вычисления расстояния между каждыми двумя точками в выборке, и поэтому большинство алгоритмов этого класса масштабируются как $O(N^2)$. Эта зависимость не позволяет эффективно ими пользоваться на больших выборках.

Применения методов на основе анализа графа соседства

О’Меара и соавт. в [41] на основе метода IDOS создали систему мониторинга АТНМоS (Automated Telemetry Health Monitoring System), которая используется в немецком центре управления полетами (GSOC). Эта система дополняет метод IDOS автоматическим подбором порогового значения аномальности точки для заданной базы номинальных значений ТМП. Получившийся в [41] метод был назван OPVID. Он дает возможность анализировать много подсистем и большое количество ТМП без значительного вмешательства оператора в процесс обучения системы. В рассмотренном в [41] примере была показана способность алгоритма выделять аномалии в исходных данных, а также сравнили работу OPVID с алгоритмом, предложенным Martinez-Heras в [42], получив значительно меньшее количество ложных положительных срабатываний. Schlag и О’Меара [43] позже провели подробную эмпирическую проверку качества работы OPVID на различных корпусах данных с использованием как вручную созданных признаков, так и полученных с помощью автоэнкодера, где показали хорошее качество работы OPVID по сравнению с LOF и LoOP.

4.2. Методы, основанные на кластеризации

Кластеризация в общем виде используется для группировки похожих элементов. Большая часть алгоритмов кластеризации не предназначена специально для поиска выбросов или аномалий, однако они могут использовать структуру имеющихся данных и на ее основе выделить аномалии по определенному критерию. В основном эти методы могут обучаться в неконтролируемом или полуконтролируемом режиме. Chandola [7] выделяет три класса

алгоритмов поиска аномалий, основанных на кластеризации, исходя из гипотез о том, что представляют собой аномалии в исходных данных:

1) нормальные данные принадлежат какому-либо кластеру, а аномалии никаким кластерам не принадлежат. В этом случае можно использовать алгоритмы кластеризации, которые не требуют принадлежности каждой точки к кластеру, например DBSCAN, ROCK [44], SNN (shared nearest neighbours) [45] и их модификации;

2) нормальные данные лежат близко к одному из выделенных центроидов, в то время как аномальные расположены далеко от них. В этом классе можно использовать методы, которые вычисляют центроид кластера, такие как метод k -средних, самоорганизующиеся карты (self-organizing maps, SOM) [46]. Кластеризация методом k -средних является самым популярным алгоритмом в этом классе;

3) нормальные данные принадлежат крупным плотным кластерам, а аномалии образуют маленькие или редкие кластеры. К этому подклассу относятся такие алгоритмы, как FindCBLOF [47], CD-trees [48].

Алгоритмы DBSCAN, ROCK и SNN основаны на исследовании графа соседства. Алгоритм DBSCAN требует установить расстояние соседства и основан на исследовании непосредственной доступности друг к другу точек получившегося графа соседства. В этом смысле DBSCAN тесно связан с предыдущей группой методов. Алгоритм способен выделять ядро кластера — точки, которые имеют по меньшей мере n соседей, точки, относящиеся к кластеру, но не являющиеся ядром, и выбросы.

Алгоритмы ROCK и SNN (Shared Nearest Neighbours) используют понятие связи, которое представляет собой количество потенциальных общих соседей между двумя кластерами, или, что то же самое, количество возможных связей длины два между кластерами в графе соседства. Алгоритм ROCK разработан для случаев, когда необходимо кластеризовать векторы из категориальных переменных, и может использовать неметрическую функцию сходства, которая основана на таблице сходства. В этом методе для кластеризации предлагается считать каждую точку отдельным кластером и используют рекурсивный механизм их объединения. Таким образом, в отличие от k -средних ROCK не требует задания числа кластеров. Использование количества общих соседей для вычисления сходства двух векторов смягчает проблемы, связанные с большой размерностью данных и уменьшающейся плотностью.

Метод k -средних, k -medoids и самоорганизующиеся карты широко известны. Они используют понятие центроида и группируют элементы на основании удаленности от него, после чего меняют координаты центроида на центр масс принадлежащих ему элементов. При применении этих алгоритмов аномальными считают данные, лежащие далеко от обнаруженных центроидов.

Третий подкласс алгоритмов производит кластеризацию одним из существующих алгоритмов кластеризации, после чего объявляет некоторые кластеры аномальными на основе таких критериев, как, например, плотность кластера, количество точек в нем или по некоторой существующей разметке. Алгоритм FindCBLOF [47] — модифицированный для кластеризации алгоритм, основанный на локальной плотности точек.

Преимущества методов, основанных на кластеризации:

- 1) могут обучаться без учителя;
- 2) могут работать с разными типами данных;
- 3) хорошо подходят к небольшим сферическим датасетам.

Недостатки методов, основанных на кластеризации:

1) аномалии бинарны, т.е. алгоритмы не присваивают значения аномальности;

2) многие методы чувствительны к начальному выбору числа кластеров, однако при анализе временного ряда в реальном времени число кластеров невозможно узнать заранее;

3) многие методы опираются на расстояние, и потому их эффективность снижается на пространстве большой размерности;

4) методы, основанные на центроидах, чувствительны к их начальным расположениям, страдают от проклятия размерности в очень больших датасетах, чувствительны к выбросам.

Применения методов, основанных на кластеризации

Iverson в [49] представил алгоритм, который назвал индуктивной системой мониторинга (inductive monitoring system, IMS). За основу Iverson взял алгоритм k -средних и предложил механизм увеличения числа выделяемых кластеров в процессе анализа данных. Для этого используется пороговое значение удаленности вновь наблюдаемой точки от уже существующих кластеров. Алгоритм обучается на данных номинальных режимов работы и предполагается, что точки, лежащие вдали от выделенных центров кластеров, являются аномальными. Системы, основанные на IMS, использовались для мониторинга состояния гиродинов и системы обеспечения теплового режима на международной космической станции [50]. Похожие принципы для построения системы контроля состояния наноспутника предлагает Singh в [51].

Chen и соавт. в [52] использовали данные наземного эксперимента с измерениями вибраций в подшипниках управляющих двигателей-маховиков (УДМ), чтобы отличить нормально функционирующие подшипники от подшипников с проблемами во внешнем кольце или сепараторе. В этом исследовании в качестве признаков использована корреляционная размерность показаний акселерометров. Для улучшения результатов они применяют k -medoid кластеризацию последовательно два раза: на данных корреляционной размерности и на полученных центрах кластеров в результате первой кластеризации. Результаты были валидированы на экспериментальных данных и показали хорошую различающую способность алгоритма.

Suo и соавт. в [53], предложили метод сеточной кластеризации на основе соседства и верифицировали работу метода на данных численного моделирования системы электропитания (СЭП). Алгоритм использует заранее определенный шаг сетки для определения соседних точек и использует полученную сеточную плотность для оптимизации квадратичной по количеству точек сложности классических методов, основанных на расстоянии до соседей.

4.3. Статистические методы

Статистические (или вероятностные) методы применяют в том предположении, что нормальные и аномальные данные имеют статистически разные плотности распределения вероятностей, по которым их можно различить. Основным достоинством этих методов является то, что, помимо вероятности отнесения ситуации к тому или иному классу, они позволяют вычислить и доверительные интервалы получившихся оценок. Однако в случае задачи поиска аномалий существует проблема определения пороговой вероятности, начиная с которой состояние нужно считать аномальным.

Существуют следующие подклассы статистических методов:

Параметрические методы:

- 1) смесь гауссовых распределений (Gaussian Mixture Model, GMM),
- 2) фильтры Калмана,
- 3) скрытые марковские модели,
- 4) ARIMA (autoregressive integrated moving average);

Непараметрические методы:

- 1) ядерные оценки плотности,
- 2) гистограммные.

Параметрические методы делают некоторое предположение о распределении наблюдаемых величин. Фильтры Калмана предполагают существование фиксированного набора параметров, образующих оцениваемый вектор состояния системы, который эволюционирует по известному закону (с точностью до аддитивно входящей в этот закон нормально распределенной случайной переменной). Также предполагается заданной модель наблюдения, в соответствии с которой данные измерений связаны с вектором состояния известной функцией (опять же с точностью до нормально распределенной случайной переменной). Различные модификации фильтра Калмана применяются и для оценки матрицы ковариации ошибки предсказываемых параметров. В случае если фактическое измерение произошло в области с низкой плотностью вероятности, точка помечается как аномальная.

Скрытые марковские модели работают аналогичным образом в дискретном пространстве переменных и позволяют задать функции в табличном виде.

Модель ARIMA аппроксимирует экспериментальные данные зависимостью

$$\left(1 - \sum_{i=1}^p \phi_i L^i\right) (1 - L)^d X_t = \left(1 + \sum_{i=1}^q \theta_i L^i\right) \varepsilon_t,$$

которая имеет короткое обозначение $ARIMA(p, d, q)$, где X_t — временной ряд; L^i — оператор эволюции; ε_t — независимые случайные переменные, взятые из $N(0, \sigma)$; p, d, q — параметры авторегрессионной (AR), интегральной (I) моделей и модели бегущего среднего (MA) соответственно; ϕ_i и θ_i — параметры модели. Частными случаями этой модели являются:

— $ARIMA(0,0,n)$ — скользящее среднее в окне шириной n ,

— $ARIMA(0,n,0)$ означает, что n -я производная временного ряда является постоянной,

— $ARIMA(n,0,0)$ — авторегрессия по n предыдущим состояниям.

Гистограммные методы являются способом оценки функции вероятности для категориальных или дискретных переменных, которые работают путем простого подсчета и нормировки. Ядерная оценка плотности вероятности — естественное обобщение этого метода для оценки непрерывных функций распределения.

Достоинства статистических методов:

- хорошая математическая обоснованность;
- модель не требует много памяти для хранения.

Недостатки статистических методов:

- возникновение проблем при несоответствии экспериментальных данных сделанным предположениям о функции распределения;
- малая эффективность при небольшом количестве данных или большой размерности;
- непараметрические методы не могут эффективно обрабатывать взаимосвязи между переменными.

Применения статистических методов

Azevedo и соавт. в [54] применяют алгоритмы кластеризации k -средних и expectation maximization, предполагая, что нормальные данные представляют собой смесь нормальных распределений. Они показали, что оба алгоритма достаточно чувствительны, чтобы обнаружить аномалию, связанную со слишком большим зарядом аккумуляторной батареи, за шесть часов до превышения порогового значения.

Rahimi и соавт. в [55] представили подход, основанный на сигма-точечном фильтре Калмана для определения аномалий в управляющих двигателях-маховиках (УДМ). Аномальное функционирование системы детектируется при выходе значений контролируемых ТМП за три среднеквадратичных отклонения, вычисленных в окне некоторой наперед заданной ширины. В случае аномального функционирования в [55] предлагается адаптировать алгоритм фильтрации, изменяя соответствующие аномальным значениям контролируемых параметров диагональные элементы матрицы ковариации ошибок. Демонстрируется работа алгоритма на модели УДМ в случае разных сценариев нештатной работы (при модельных аномалиях во входном напряжении УДМ). Показано, что разработанный алгоритм способен детектировать указанные модельные аномалии, при этом оценка контролируемых параметров УДМ остается удовлетворительной, что позволяет поддерживать функционирование системы.

Yairi и соавт. в [56] предложили алгоритм, который объединяет вероятностный анализ главных компонент непрерывных переменных и вероятности дискретных состояний, расширив, таким образом, подход к моделированию распределения, предложенный Tipping и Bishop в [57]. В результате анализа получается временной ряд с оценкой аномальности исходных данных. В [56] используются данные японского спутника JAXA SDS-4, включая его системы ориентации и стабилизации (СОС), электропитания (СЭП), обеспечения теплового режима (СОТР). В результате анализа можно было отличить друг от друга разные режимы работы КА, а также выявить аномалию в работе СОС.

Также в [56] обсуждаются различные варианты предварительной обработки исходных данных.

Adnanе и соавт. в [58] демонстрируют модификацию обобщенного фильтра Калмана для улучшения оценки состояния в контуре СОС при различных сценариях ошибок в измерениях магнитометра. Показано, что предложенный алгоритм способен в реальном времени определять и оценивать ошибки магнитометра. Алгоритм был протестирован на данных моделирования микроспутника высокой точности.

Ahmed и соавт. в [59] предложили применить метод Каплана—Мейера [60] после предварительной классификации, основанной на логическом анализе данных (LAD). В [59] используется датасет от NASA Ames Prognostics для классификации аккумуляторных батарей по их состоянию на основе емкости и показали, что этот способ улучшает результат оценки вероятности отказа по сравнению только с методом Каплана—Мейера.

4.4. Классификационные методы

Классификационные методы исходят из общего предположения о том, что может быть создан классификатор, который способен надежно отделять нормальные состояния от аномальных в заданном пространстве признаков. В основном эти методы служат для идентификации известных аномалий. К классификационным методам можно отнести следующие типы алгоритмов:

1) основанные на методе опорных векторов, в том числе с использованием ядерных функций,

2) основанные на нейронных сетях,

3) основанные на правилах,

4) основанные на байесовских сетях.

Все эти алгоритмы работают в режиме обучения с учителем, поэтому требуют размеченных данных для обучения.

Метод опорных векторов (support vector machine, SVM) ищет гиперплоскость в пространстве признаков, способную разделить обучающую выборку на два класса. Этот метод может быть адаптирован для обнаружения нелинейной границы при помощи механизма ядерной функции. Весьма популярным является классификация методом k ближайших соседей (k nearest neighbours, k NN).

Для классификации также могут быть использованы различные типы нейронных сетей, такие как сети прямого распространения (их также называют MLP, multilayer perceptron), рекуррентные сети, в том числе с GRU (gated recurrent unit) из [61] или LSTM (long short-term memory) из [62] нейронами, сверточные сети (convolutional neural net, CNN), а также другие типы, используемые самостоятельно или последовательно с другими алгоритмами.

Методы, основанные на правилах, включают в себя поиск ассоциативных правил [63], логический анализ данных (logical analysis of data, LAD) и основанные на них методы. К ним иногда относят методы, основанные на решающих деревьях. При этом на обучающей выборке строится некоторое интерпретируемое правило. Данные, ему не подчиняющиеся, считаются аномальными. Все методы, основанные на Байесовских сетях, делают оценку постериорной вероятности наблюдения метки определенного класса. Простой

Байесовский классификатор является самым простым и самым популярным методом этой группы. Базовая техника предполагает независимость переменных друг от друга. Однако возможно ее обобщение с использованием более сложных байесовых сетей.

Часто к классификационным методам относят методы одноклассовой классификации. Они характеризуются тем, что в обучающей выборке присутствуют представители только одного класса, а в случае поиска аномалий — представители нормальной работы системы. Алгоритм строит границу области, в которую попадают все эти представители, а объекты вне этой области считаются аномальными. Наиболее часто применяемым методом этой категории является ОС-SVM (one-class support vector machine) [64].

Das и Mattews в [65] разработали метод MKAD (Multiple Kernel Anomaly Detection), который комбинирует в одном ядре метрику LCS (longest common subsequence) из [66] для дискретных переменных и ядро на основе SAX (symbolic aggregate approximation) из [67] представления непрерывных переменных для одноклассовой классификации методом ОС-SVM. В [65] продемонстрировано преимущество предложенной схемы над алгоритмами ORCA и SequenceMiner при поиске значимых отклонений в полетных данных.

Преимущества классификационных методов:

- возможно использование готовых алгоритмов классификации;
- достаточно быстрая работа созданных моделей.

Недостатки классификационных методов:

- классификационные методы опираются на эталонную разметку в обучающей выборке, которая далеко не всегда доступна;
- присваивают только дискретную метку, что усложняет ранжирование результатов.

Применения классификационных методов

Ke Li и соавт. исследовали различные методы классификации временных рядов. В [68] используется алгоритм fuzzy c-means и выделение признаков с помощью метода главных компонент (principal component analysis, PCA), которые могут использоваться для облегчения разметки данных оператором, после чего применили модификацию метода опорных векторов WPSVM (weighted proximal support vector machine) для классификации сигналов системы электропитания космического аппарата (КА) на нормальные и аномальные. Было изучено качество работы алгоритма при разных подходах к многоклассовой классификации методом опорных векторов: разграничение классов попарно и один из классов с остальными, а также сравнили WPSVM с работой наивного Байесовского классификатора и метода К ближайших соседей (kNN). Кроме того, было показано, что быстродействие WPSVM позволяет использовать его в режиме реального времени. В [69] исследован способ выделения признаков на основе глубокой сети доверия (deep belief network) и последующую классификацию с помощью случайного леса. Предварительно была произведена фильтрация данных с помощью вейвлет-преобразования. Для сравнения в [69] приведены также результаты классификации другими алгоритмами: kNN, SVM, наивным Байесовым классификатором с использованием нескольких методов выделения признаков: PCA, многоуровневых автокодировщиков (stacked autoencoder), а также на исходных данных.

Воронцов в [70] предложил использовать сеть прямого распространения для классификации режимов работы СОТР и СЭП. На выборке из 50 тестов была продемонстрирована работа алгоритма и достигнута частота ложных положительных и ложных отрицательных срабатываний до 20 и 10 % соответственно.

Nassar, Hussein и соавт. в [71, 72] сравнили два алгоритма, обучающихся с учителем: дискриминантный анализ при помощи частных наименьших квадратов (partial least squares discriminant analysis, PLS-DA), ядерный метод опорных векторов (kernel support vector machine, KSVM) и результаты расчета в коммерческом пакете. В работах [71, 72] заявляется что подход, основанный на PLS-DA, отделяет аномальные данные лучше, чем PCA, который только ищет направление максимальной изменчивости в данных. Система была протестирована на 16 ТМП системы ориентации и стабилизации КА.

Fuertes и соавт. в [73] представили ограничения классических подходов поиска аномалий по пороговым значениям и описали созданный программный продукт NOSTRADAMUS, который использовался для контроля ТМИ аппарата CNES. Этот продукт уменьшает размерность данных и производит одноклассовую классификацию методом опорных векторов. Авторы описали примеры использования этой системы на ошибках СОТР и осцилляциях показаний звездного датчика. Кроме того, они сравнили методы ОС-SVM, kNN и LOF, кратко описали достоинства и недостатки этих методов. В заключение авторы описали концепцию работы, функционал и архитектуру выбранного решения для внедрения и большей автоматизации работы операторов.

Galal и соавт. в [74] использовали метод главных компонент и байесовский классификатор на ТМИ аккумуляторной батареи КА. Для разметки аномальных данных они использовали режим штатной проверки работоспособности СЭП, поскольку в этом режиме батарея испытывает аномально большие для нормальной работы нагрузки. Для валидации использовались данные деградировавшей после аварии аккумуляторной батареи. В [74] удалось понизить размерность исходных данных с 30 до 5 без существенных потерь в качестве классификации и достигнуть точности 0,95 по метрике AUC ROC.

На данных ТМИ СЭП космического аппарата EgyptSat-1 Ibrahim и соавт. [75] применили SVM регрессию из [76] для предсказания поведения временного ряда и продолжили работать над интерпретируемостью результата с использованием метода под названием логический анализ данных (logical analysis of data, LAD) [77], который тренируется на результатах K-means кластеризации. Комбинируя этот подход с анализом дерева отказов, в [75] оценили наиболее вероятную причину возникновения отказа для расследования возможных причин потери КА EgyptSat.

К сожалению, во многих публикациях авторы приводят только метрику правильности классификации и не указывают показатели точности и полноты распознавания каждого класса или матрицы ошибок. Именно эти показатели являются критически важными для практических применений и анализа результатов при несбалансированных выборках, которые имеют место при работе с отказами и аномалиями. Кроме того, эти метрики обычно применяются к неструктурированным данным, а их применение к временным рядам имеет некоторые особенности.

4.5. Методы, основанные на реконструкции

Методы, основанные на реконструкции, предполагают, что можно построить некоторую модель данных. Сравнивая текущие показания датчиков с данными, рассчитанными с помощью этой модели, можно обнаружить аномалию. Другими словами, основанные на реконструкции методы используют ошибку реконструкции данных для разделения их на нормальные и аномальные. Обученный на нормальных данных алгоритм будет давать существенную ошибку восстановления на аномальных данных.

Можно условно разделить эти методы на методы, основанные на восстановлении сигнала, и на методы, основанные на предсказании.

Методы первого класса, по сути, предполагают, что в каждом состоянии показания датчиков связаны некоторой зависимостью, поэтому могут быть полностью описаны меньшим количеством переменных. Одним из самых популярных методов является метод главных компонент (РСА), в том числе с использованием ядерных функций. К этому классу также относятся методы, основанные на автокодировщиках.

Методы, основанные на предсказании, предполагают, что исходя из данных можно построить модель их эволюции при номинальном режиме работы. К таким методам можно отнести различные типы нейронных сетей, в том числе рекуррентные, прямого распространения и генеративные.

Преимущества методов, основанных на реконструкции:

- облегчают проблемы, связанные с многомерными данными, поскольку автоматически понижают их размерность;
- могут быть использованы в режиме неконтролируемого обучения.

Недостатки методов, основанных на реконструкции:

- полезны только в случае, если в некотором пространстве признаков аномалии отделимы;
- обычно имеют высокую вычислительную сложность.

Применения методов, основанных на реконструкции

Абрамов и соавт. в [78] предложили использовать нейронную сеть прямого распространения для рекурсивного предсказания временного ряда, после чего были использованы пороговые методы для обнаружения аномалий в предсказанном временном ряде. Этим методом была предсказана работа системы на 4 мин и достигнута точность предсказания нештатной ситуации в 0,887 при полноте 0,938.

О’Меага и соавт. [28] исследовали возможности нейронных сетей прямого распространения для предсказания временного ряда из агрегированной за виток статистики ТМП и детектировали появление аномалии по рассогласованию значений измеренных параметров с предсказанными. Кроме того, в [28] были исследованы возможности поиска аномалий системой АТНМоС с помощью признаков, выделенных с помощью автокодировщика, а также в сочетании с признаками, заданными вручную. В первой части [28] удалось корректно предсказать поведение агрегированных параметров на три витка вперед. Во второй части было показано, что для надежного выделения аномалий признаки, заданные вручную, играют большую роль при обнаружении аномалий.

Martinez-Heras и Donati в [79] использовали глубокий автокодировщик для поиска аномалий в телеметрии КА Mars Express и предположили, что рекуррентные нейронные сети могут быть использованы для определения пороговых значений.

Petković и соавт. [80] предлагают метод конвейерной обработки (batch processing) для предсказания потребления системы обеспечения теплового режима на КА Mars Express. Они использовали ручное выделение признаков и ансамблевые методы, такие как случайный лес и градиентный бустинг на решающих деревьях, для создания предиктивной модели. Их модель использовалась для распределения энергии на научные эксперименты. В [80] отмечается, что модель может использоваться для поиска аномалий по разладке предсказанного и измеренного энергопотребления.

Ibrahim и соавт. [81] сравнили различные методы глубокого обучения на ТМИ, полученной от одной из составных частей КА EgyptSat. Они использовали различные архитектуры, такие как ARIMA, MLP (Multilayer perceptron), RNN, LSTM, GRU, DLSTM и DGRU, для предсказания поведения временного ряда. Сравнение производилось по метрикам качества точности предсказания: среднеквадратичной ошибке, средней абсолютной ошибке, коэффициенту корреляции, метрике r^2 и времени обучения. В результате был сделан вывод, что для КА с небольшим временем активного существования, около 3–5 лет, лучше подходят более простые методы, такие как ARIMA, для предсказания временного ряда во время штатной работы.

Omrán и Murtada исследовали возможности извлечения признаков для классификации отказов при помощи метода Прони. В [82] была использована рекуррентную нейронную сеть, натренированную на признаках, выделенных с помощью метода Прони для поиска аномалий в работе маховиков. В качестве исходных данных были использованы данные высокоточного численного моделирования. После этого была использована простая сеть прямого распространения для классификации найденных аномалий на известные классы нештатной работы рассматриваемой подсистемы. В результате алгоритм был способен корректно определять все виды моделируемых неисправностей и корректно выделять ранее неизвестные ему режимы работы с точностью, близкой к 100% и превосходящей точность таких алгоритмов, как ARMA, PCA и SVM. В [83] были исследованы возможности метода Прони для извлечения признаков и последующей идентификации отказов солнечной батареи и устойчивости такого алгоритма к шуму. В качестве исходных данных использовались данные численного моделирования. С помощью сети прямого распространения в [83] были затем идентифицированы десять различных видов отказов в шумных данных.

Shin и Tariq в [84] описали систему, внедренную для мониторинга состояния КА KOMPSAT-2 в Korea Aerospace Research Institute (KARI). Как и в [28], были использованы статистически агрегированные по каждому ТМП за каждые 10 мин признаки: среднее, максимальное и минимальное, медианное значение, среднюю энергию сигнала и т.п. В отличие от [28], эти данные обрабатывались как тензор третьего порядка, используя CANDECOP/ PARAFAC разложение из [85]. После этого была применена кластеризация на строках одной из матриц в разложении, чтобы зарегистрировать момент воз-

никновения аномалии. В заключительной части анализа был применен метод определения динамического порога, предложенный Hundman в [86].

Pilastre [87] предложил метод обнаружения аномалий, основанный на разреженном линейном представлении отрезков сигнала. Метод работает с временными рядами с дискретными и непрерывными ТМП и работает в два этапа. На первом этапе находятся представление проекции только дискретных переменных и соответствующий этим дискретным переменным словарь непрерывных переменных. В случае, если такое представление может быть найдено, второй этап конструирует непрерывный сигнал из линейной комбинации компонент словаря непрерывных переменных. Детектирование аномалии возможно на первом этапе, если представление дискретных переменных из словаря невозможно, и на втором этапе, если ошибка реконструкции сигнала превышает заданный порог.

4.6. Ансамблевые методы

Ансамблевые методы подробно обсуждались Aggarwal [88]. К ним прежде всего относятся различные мета-алгоритмы, т.е. алгоритмы, использующие и комбинирующие другие алгоритмы в своей работе. Можно выделить две категоризации ансамблевых методов: по независимости компонент и по их типу.

В ансамблях с независимыми компонентами различные алгоритмы применяются на разных частях исходных данных или их разных компонентах, после чего комбинируются для получения более устойчивого результата. Случайный лес является типичным представителем этого класса. При последовательном построении ансамбля каждый следующий алгоритм зависит от результата предыдущего. Это происходит, например, при использовании градиентного бустинга.

В категоризации по типу компонент Aggarwal выделяет ансамбли, ориентированные на модели, и ансамбли, ориентированные на данные. Первые агрегируют результаты различных по своей природе базовых алгоритмов. При этом возникают проблемы, связанные с различными типами результатов каждого из алгоритмов. Например, результатом одного алгоритма может быть значение от (-1) до 1 , а результатом другого – условная вероятность выброса.

Ансамбли, ориентированные на данные, могут использовать часть данных для построения каждой предсказательной модели, после чего агрегировать их результаты для получения более устойчивого результата. Случайный лес – представитель этого класса алгоритмов.

Преимущества ансамблевых методов:

– в некоторых случаях возможно сочетать преимущества различных методов;

– в случае независимых компонент ансамбля алгоритмы легко масштабируются на многопроцессорные вычисления.

Недостатки ансамблевых методов:

– как правило, высокая вычислительная сложность из-за необходимости строить несколько моделей.

Применения ансамблевых методов

Carlton и соавт. в [89] использовали статистические подходы для поиска интересующих их точек временного ряда, после чего группировали резуль-

таты по одинаковым компонентам в разных КА или по разным компонентам одного КА исходя из близости найденных точек по времени. Если точек в одной или нескольких группах в какой-то момент оказывалось много, то этот момент времени получал большой показатель аномальности и соответствующие данные выводились на экран оператора. В [89] была проведена валидация этого подхода с использованием данных с телекоммуникационных спутников Intelsat и Inmarsat и базы данных SpaceTrak¹.

Nozari и соавт. в [90] предложили анализировать при помощи нейронной сети прямого распространения результаты различных классификаторов и продемонстрировали работу сети на методе опорных векторов, PLS (partial least squares), случайном лесе с использованием данных о работе УДМ.

5. Определение пороговых значений

В результате применения многих из описанных методов, в частности статистических методов или методов, основанных на реконструкции, получается временной ряд с оценкой аномальности соответствующего состояния. Однако при этом возникает упомянутая проблема определения порогового значения аномальности, начиная с которого необходимо предупреждать оператора о возможном приближении нештатной ситуации. Часто это происходит путем эмпирического определения некоторого порогового значения, исходя из информации об уже известных отказах и выбирая соотношение между количеством ложных положительных и ложных отрицательных ответов.

Как правило, длительная работа на режимах, близких к пороговым, является признаком аномальных процессов. Тем не менее поиск аномалий с использованием пороговых значений не способен выявить такие режимы работы. Hundman и соавт. [86] предложили метод динамического определения порогового значения при анализе временных рядов, который способен справиться с этой проблемой. В [86] было предложено определять пороговое значение в зависимости от длительности и величины ошибки предсказания сигнала, а также механизм фильтрации ложных положительных результатов. Работа алгоритма была продемонстрирована с использованием Numenta Anomaly Benchmark, а также данных КА Soil Moisture Active Passive (25 ТМП) и Mars Science Laboratory (55 ТМП).

Pang [91] предложил критерий ширины покрытия (coverage width criterion) для вычисления порогового значения аномальности состояния как гиперпараметра модели при использовании вероятностных моделей. Эффективность данного метода была проверена на ТМИ системы электропитания КА Fengyun.

6. Метрики качества методов

Для задач классификации и кластеризации типичными мерами качества алгоритма являются точность (precision) и полнота (recall):

$$\text{Точность} = \text{ИП}/(\text{ИП} + \text{ЛП}),$$

$$\text{Полнота} = \text{ИП}/(\text{ИП} + \text{ЛО}),$$

¹ <https://www.seradata.com/products/spacetrak/>

где ИП – истинные положительные, ЛО – ложные отрицательные, ЛП – ложные положительные результаты классификации. Таким образом, точность отражает долю правильных ответов из всех точек, которые система отнесла к данному классу, а чувствительность, которую также называют полнотой, отражает долю правильно классифицированных точек из всех точек данного класса. Как правило, совместное улучшение этих показателей оказывается невозможным, и необходимо выбирать баланс между ними для каждой задачи. Например, в очень крупных системах с большой устойчивостью можно пожертвовать точностью. В то время как если цена ошибки очень высока, то необходимо оптимизировать чувствительность ценой появления большего количества ложных положительных результатов. Точность и полноту часто комбинируют в F-меру, которая определяется как их среднее геометрическое.

Эти метрики предназначены для анализа классификации отдельных объектов, однако они не полностью применимы к временным рядам, поскольку игнорируют их структуру. Lavin и соавт. [92] предложили метрику *Numenta anomaly benchmark*, которая в некоторой мере учитывает последовательную структуру временного ряда и вознаграждает раннее обнаружение аномалий. В [92] предполагается, что идеальный детектор обладает следующими свойствами:

- 1) выделяет все аномалии в данных,
- 2) выделяет аномалии как можно раньше, в идеале – до того, как их заметит человек,
- 3) не дает ложных срабатываний,
- 4) работает с данными в реальном времени,
- 5) полностью автоматизирован для работы с разными наборами данных.

Исходя из этих требований окно заданной ширины вокруг точечной аномалии, в котором срабатывание детектора вознаграждается, а срабатывание вне этого окна считается ложным и штрафуются. Таким образом, эта метрика работает с аномалиями как с точечными, но учитывает временную структуру данных. В дополнение к этим методам вычисления метрик в работе [92] представлен корпус данных *Numenta NAB Data Corpus*², который содержит одномерные временные ряды из различных областей, таких как информационные и коммуникационные технологии, системы кондиционирования в зданиях и др. Эти данные имеют эталонную разметку и алгоритмы для оценки эффективности поиска аномалий.

Lee и Tatbul [93] предложили настраиваемые метрики качества поиска аномалий во временных рядах, которые обобщают понятия точности и полноты для множеств. Эти метрики учитывают частичное пересечение идентифицированных и настоящих аномалий путем введения функций, которые некоторым образом штрафуют разные виды неточностей определения аномальных интервалов. Эта метрика может учитывать специфику решаемой задачи путем введения других функций для штрафа за ошибки и вознаграждения за найденные аномалии. При этом путем выбора определенных функций вознаграждений и штрафов эта метрика может быть сведена к метрике, предложенной в [92], и потому является более общей.

² <https://github.com/numenta/NAB/tree/master/data/>

Отметим, что для корректной оценки качества и количественного сравнения работы различных алгоритмов обе метрики требуют наличия эталонной разметки аномалий.

7. Применения и перспективы развития в космической технике

Опишем существующие промышленные системы мониторинга, основанные на анализе данных, которые использовали или используют различные космические агентства для облегчения эксплуатации космических аппаратов, возможные варианты развития использующихся методов, а также открытые источники данных, которые могут быть использованы для тестирования разрабатываемых открытым сообществом алгоритмов.

Одной из первых систем, основанных на анализе данных, стала Inductive Monitoring System, разработанная Iverson и соавт. в NASA [49]. Ее принцип работы основан на алгоритме k-means, однако существенным отличием является доработка, позволяющая динамически увеличивать количество кластеров. Этот метод требует наличия базы данных номинальных состояний и обеспечивает выделение состояний, которые лежат достаточно далеко от известных номинальных состояний.

O'Meara [41] представил систему, использующуюся в немецком центре управления полетами (GSOC) DLR. Система берет за основу алгоритм IDOS [33], работающий на основе анализа плотности точек, вычисленной на основе оценки локальной естественной размерности данных, и дополняет его алгоритмом для выбора порогового значения для каждого ТМП. Кроме того, в [28] кратко описывается основная инфраструктура системы мониторинга.

Columbus Control Centre DLR внедрил Project Sibyl [94] в качестве системы обнаружения аномалий для контроля пилотируемых космических полетов. В системе реализован алгоритм LoOP на основе фреймворка ELKI [95]. В дальнейших планах стоит использование наработок Sibyl в проекте ATHMoS для создания единой системы мониторинга ТМИ для всех миссий GSOC.

CNES разработал совместно с TESA и внедрил систему NOSTRADAMUS [73] для контроля полета своих КА. В [73] описан основной функционал системы и концепция ее работы, основные промежуточные шаги анализа данных. В заключение [73] приведено описание основных недостатков системы, выяснившихся в процессе эксплуатации, таких как повышенная чувствительность к входным данным (из-за особенностей работы выбранного за основу алгоритма OC-SVM) и сложности интерпретации результата.

Системы мониторинга, основанные на данных, также работают в JAXA [56] и NASA JPL [86], Korea Aerospace Research Institute (KARI) [84]. Однако в [56, 84, 86] приведено описание только математического метода анализа информации и не описана инфраструктура решения.

Видно, что многие космические агентства активно эксплуатируют и занимаются внедрением различных математических методов для анализа ТМИ, организуют необходимую для этого вычислительную инфраструктуру и доступ к многолетней ТМИ для необходимой валидации созданных алгоритмов.

Существует также несколько открытых источников с информацией:

— Nasa Prognostics Center of Excellence³ предоставляет доступ к данным от различных организаций и университетов, которые могут быть использованы для изучения и отладки алгоритмов⁴;

— с 2019 г. открыт доступ к ТМИ космического аппарата GOCE [96], который содержит около 13 000 ТМП, однако он не содержит разметки данных с указанием поломок и аномалий;

— в 2016 г. были проведены открытые соревнования по созданию эффективной предсказательной модели системы терморегуляции для аппарата Mars Express Orbiter [30]. Данные представляют собой архив за три марсианских года, включающих в себя контекст (например углы на Солнце, журналы от-данных команд и т.п.) и данные наблюдений (потребление 33 ТМП СОТР). Задача состояла в предсказании потребления СОТР на четвертый год;

— SpaceTrak⁵ — коммерчески поддерживаемая база данных происшествий с космической техникой. Эта база не содержит ТМИ, но может служить источником данных для валидации или других исследований надежности.

К сожалению, по имеющейся на данный момент информации, не существует корпуса данных спутниковой ТМИ с разметкой аномалий или неисправностей. Ограниченное наличие данных значительно затрудняет разработку и валидацию как специализированных методов, так и методов общего назначения для мониторинга КА.

Несмотря на значительные успехи и широкое применение в промышленности, существует значительный запрос на новые разработки. К ним относятся технологии активного обучения для поиска аномалий. Этот запрос обусловлен большим количеством поступающей информации и принципиальной невозможностью полной ручной разметки.

Кроме того, большая часть алгоритмов машинного обучения предполагает, что тренировочные и тестовые данные принадлежат одному и тому же распределению. Однако на практике данное условие не выполняется ввиду нестабильности производства и различных условий, в которых находятся КА. Поэтому при применении модели, обученной на работе одного из КА группировки, к другому КА будут возникать неточности. Недавно для преодоления этих сложностей начали использоваться техники предметной адаптации [97]. Эта тема требует дополнительных исследований для задач технической диагностики.

Остается открытым вопрос об использовании экспертного знания и физических моделей, их интеграции в процесс автоматизированной технической диагностики. Некоторые исследования показали, что это может улучшить точность и интерпретируемость результата [98]. Tipaldi [3] предложил возможную архитектуру такого решения. Подробный обзор перспектив глубокого обучения для задач управления техническим состоянием был проведен Fink и соавт. [99].

³ <https://ti.arc.nasa.gov/tech/dash/groups/pcoe/>

⁴ <https://ti.arc.nasa.gov/tech/dash/groups/pcoe/prognostic-data-repository/>

⁵ <https://www.seradata.com/products/spacetrak/>

8. Заключение

В статье рассмотрены основные типы методов анализа данных, использующихся для анализа телеметрической информации (ТМИ) и поиска аномалий в ней, и основные публикации о применении этих методов. Были описаны особенности постановки задачи и валидации работающих на этом принципе систем мониторинга состояния КА, а также обсуждались возможные метрики качества работы алгоритмов и вопросы выбора пороговых значений степени аномальности для необходимого баланса между этими метриками. Кратко обозначены возможные перспективы развития в этой области.

Можно видеть [11], что большинство алгоритмов быстро теряет свою эффективность при увеличении количества анализируемых ТМП, поэтому многие работы так или иначе старались выделить признаки, имеющие меньшую размерность, чем исходные данные. Эта проблема широко известна под названием “проклятие размерности”. Для борьбы с ней может быть полезна разумная сегментация задачи мониторинга по параметрам отдельных составных частей КА с последующей агрегацией результатов.

Самыми популярными методами для обнаружения аномалий являются методы, основанные на плотности, которая вычисляется тем или иным способом, а также методы, основанные на реконструкции, а одним из самых эффективных способов улучшить качество моделей является проработка особенностей конкретных составных частей КА и тщательная подготовка признаков. Часто этот фактор является решающим в качестве модели, а не алгоритм, по которому эта модель работает. Несмотря на это можно видеть, что большинство публикаций учитывает только ТМИ, принятую с борта конкретного КА, не принимая во внимание факторы космической погоды и ее прогноза, что является крайне важным в работе КА.

Многие работы (см. приложение) используют искусственно сгенерированные данные для валидации своих алгоритмов. При этом остается открытым вопрос о возможности распространения таких результатов на реальные полетные данные. Многие космические агентства, имеющие доступ к данным для создания и валидации алгоритмов, разрабатывают и внедряют собственные системы для мониторинга технического состояния. Эти системы показывают эффективную работу в промышленном использовании и снижают нагрузку на операторов.

К сожалению, на данный момент не существует достаточного количества различных открытых данных с ТМИ КА и эталонной разметкой. Это делает невозможным повторение и подтверждение публикуемых работ, учет различных особенностей составных частей КА, а также сравнение эффективности работы экспертов и алгоритмов различных типов. Эти факторы значительно затормаживают развитие и внедрение автоматизированных систем контроля технического состояния КА. Для адаптации систем общего назначения под специфику работы КА необходимо создание соответствующего корпуса размеченных данных, а также объективных метрик для оценки и сравнения качества работы различных алгоритмов и операторов.

Кроме того, для улучшения качества прогноза технического состояния КА необходимо учитывать условия космической погоды и интегрировать эту информацию в системы поддержки принятия решений. С другой стороны, необ-

ходимы методы разбиения задачи контроля состояния всего КА на задачи меньшей размерности, например по его составным частям, методы понижения размерности путем более эффективного представления информации для улучшения работы алгоритмов, поскольку их эффективность напрямую связана с плотностью исходных данных.

Несмотря на перечисленные сложности и нерешенные задачи, системы мониторинга технического состояния КА, основанные на данных, уже используются во многих космических агентствах по всему миру и зарекомендовали себя как важный инструмент технической диагностики.

ПРИЛОЖЕНИЕ

Таблица. Перечень работ

Публикация	Данные	Выделение признаков	Метод
1	2	3	4
Iverson, 2004 [49]	Columbia Space Shuttle	нет	Кластеризация
Azevedo, 2012 [54]	СЭП бразильского КА	нет	K-means, Статистические (EM)
Li, 2015 [68]	Данные моделирования СЭП	РСА	Fuzzy C-means, WPSVM
Fuertes, 2016 [73]	КА CNES	статистические параметры сигнала в окне	PCA + OC-SVM
O'Meara, 2016 [41]	Маховики КА ТЕТ-1	Вектор из сводной информации по каждому ТМП за виток	OPVID
Verzola, 2016 [94]	запоминающее устройство (Mass Memory Unit) Columbus Orbital Laboratory	Время дня, координаты, положение солнца, данные космической погоды	Вероятностные параметрические
Nassar, 2017 [72]	16 ТМП СОС	нет	классификация PLS-DA, KSVM
Rahimi, 2017 [55]	Численное моделирование		P-адаптивный фильтр Калмана
Yairi, 2017 [56]	СЭП КА JAXA SDS-4		Байесовская классификация + Stochastic PCA
Chen, 2018 [52]	Лабораторный эксперимент с УДМ СОС	Корреляционная размерность	K-medoids(2 раза)
Pang, 2018 [91]	СЭП с КА FENGYUN	нет	LS-SVM, Gaussian Process Regression, Restricted Vector Machine
Adnane, 2018 [58]	Численное моделирование СОС		Обобщенный фильтр Калмана

Таблица (продолжение)

1	2	3	4
Carlton, 2018 [89]	Intelsat, Inmarsat		Поиск временных явлений, точек перехода статистическими методами, группировка событий
O'Meara, 2018 [28]	Несколько лет исторической информации о работе КА	Выделены как вручную, так и с помощью автокодировщика	Сеть прямого распространения
Martinez, 2018 [79]	991 ТМП КА Mars Express	нет	Определение пороговых значений с помощью нейронной сети прямого распространения
Gowda, 2018 [29]	ТМИ Mars Express Challenge	ручное выделение признаков	XGBoost
Suo, 2019 [22]	СЭП геостационарного КА (искусственные)	Выбраны с помощью предложенной методики	SVM
Galal, 2019 [74]	30 переменных СЭП	РСА (7 компонент)	Байесовский классификатор
Ibrahim, 2019 [81]	EgyptSat-1		ARIMA, MLP, RNN, LSTM, GRU, DLSTM, DGRU
Ahmed, 2019 [59]	Nasa Ames Prognostics		Классификация + метод Каплана–Мейера
Petkovic, 2019 [80]	СЭП Марс-Экспресс	ручное	Случайный лес, градиентный бустинг
Suo, 2019 [53]	СЭП геостационарного КА (искусственные)	нет	NGC Сеточная кластеризация на основе соседства
Omran, 2019 [82]	Численное моделирование высокой точности маховика СОС	Метод Прони	Elman RNN для детектирования по разладке и сеть прямого распространения для классификации аномалий
Murtada, 2019 [83]	Численное моделирование работы солнечных панелей с шумами	Метод Прони	Сеть прямого распространения
Nozari, 2019 [90]	Численное моделирование	Результаты других классификаторов	Мета-классификатор на основе SVM, NB, PLS, RF
Ibrahim, 2020 [75]	СОТР EgyptSat-1		OC-SVM, K-means, LAD
Pilastre, 2020 [87]	18 дней ТМИ: 1000 ТМП (90 затронуто аномалиями)	Дискретные и непрерывные параметры из окна фиксированной ширины	Anomaly Detection using Dictionary (ADDICT)

СПИСОК ЛИТЕРАТУРЫ

1. *Zolghadri A.* Advanced Model-Based FDIR Techniques for Aerospace Systems: Today Challenges and Opportunities // *Progress in Aerospace Sciences*. 2012. V. 53. P. 18–29. ISSN 0376-0421. <https://doi.org/10.1016/j.paerosci.2012.02.004>
2. *Абанин О.И., Соловьёв С.В.* Содержание и структура задач диагностики аномалий в работе бортовых систем космического аппарата // *Инж. ж.: наука и инновации*. 2019. № 6 (90). С. 7. ISSN 2308-6033. <https://doi.org/10.18698/2308-6033-2019-6-1890>
3. *Tipaldi M., et al.* On Applying AI-Driven Flight Data Analysis for Operational Spacecraft Model-Based Diagnostics // *Annual Reviews in Control*. 2020. V. 49. P. 197–211. ISSN 1367-5788. <https://doi.org/10.1016/j.arcontrol.2020.04.012>
4. *Соловьёв С.В., Мишурова Н.В.* Анализ текущего состояния процесса контроля при управлении полетом космических аппаратов // *Инж. ж.: наука и инновации*. 2016. № 3 (51). С. 3. ISSN 2308-6033. <https://doi.org/10.18698/2308-6033-2016-3-1474>
5. *Соловьёв В.А., Любинский В.Е., Жук Е.И.* Текущее состояние и перспективы развития системы управления полетами космических аппаратов // *Пилотируемые полеты в космос*. 2011. № 1 (1). С. 27–37. ISSN 2226-7298.
6. *Балушто А.Н., Романов А.А.* Искусственный интеллект в космической технике: состояние, перспективы развития // *Ракетно-космическое приборостроение и информационные системы*. 2019. Т. 6. № 1. С. 65–75. ISSN 2409-0239, 2587-9057. <https://doi.org/10.30894/issn2409-0239.2019.6.1.65.75>
7. *Chandola V., Banerjee A., Kumar V.* Anomaly Detection: A Survey // *ACM Comp. Surv.* 2009. V. 41. No. 3. ISSN 0360-0300. <https://doi.org/10.1145/1541880.1541882>
8. *Pimentel M.A.F., et al.* A Review of Novelty Detection // *Signal Processing*. 2014. V. 99. P. 215–249. ISSN 0165-1684. <https://doi.org/10.1016/j.sigpro.2013.12.026>
9. *Wang H., Bah M.J., Hammad M.* Progress in Outlier Detection Techniques: A Survey // *IEEE Access*. 2019. V. 7. P. 107964–108000. ISSN 2169-3536. <https://doi.org/10.1109/ACCESS.2019.2932769>
10. *Chalapathy R., Chawla S.* Deep Learning for Anomaly Detection: A Survey. 2019. arXiv: 1901.03407 [cs, stat]. URL: <http://arxiv.org/abs/1901.03407> (дата обр. 17.04.2020).
11. *Zimek A., Schubert E., Kriegel H.-P.* A Survey on Unsupervised Outlier Detection in High-Dimensional Numerical Data // *Statistical Analysis and Data Mining: The ASA Data Science J.* 2012. V. 5. No. 5. P. 363–387. ISSN 1932-1872. <https://doi.org/10.1002/sam.11161>
12. *Thudumu S., et al.* A Comprehensive Survey of Anomaly Detection Techniques for High Dimensional Big Data // *J. of Big Data*. 2020. V. 7. No. 1. P. 42. ISSN 2196-1115. <https://doi.org/10.1186/s40537-020-00320-x>
13. *Gavrilovski A., et al.* Challenges and Opportunities in Flight Data Mining: A Review of the State of the Art // *AIAA Infotech @ Aerospace*. San Diego, California, USA: AIAA, 2016. ISBN 978-1-62410-388-9. <https://doi.org/10.2514/6.2016-0923>
14. *Khan S., Yairi T.* A Review on the Application of Deep Learning in System Health Management // *Mech. Systems and Signal Processing*. 2018. V. 107. P. 241–265. ISSN 0888-3270. <https://doi.org/10.1016/j.ymssp.2017.11.024>
15. *Basora L., Olive X., Dubot T.* Recent Advances in Anomaly Detection Methods Applied to Aviation // *Aerospace*. 2019. V. 6. No. 11. P. 117. <https://doi.org/10.3390/aerospace6110117>
16. *Соловьёв В.А., Лысенко Л.Н., Любинский В.Е.* Управление космическими полетами. Уч. пос. Ч.1. М.: МГТУ им. Баумана, 2009. ISBN 978-5-7038-3351-3.

17. *Gao Z., Cecati C., Ding S.* A Survey of Fault Diagnosis and Fault-Tolerant Techniques – Part I: Fault Diagnosis with Model-Based and Signal-Based Approaches // *IEEE Trans. on Industrial Electronics*. 2015. V. 62. No. 6. P. 3757–3767. <https://doi.org/10.1109/TIE.2015.2417501>
18. *Barber D.* Bayesian Reasoning and Machine Learning, 1st edition. Cambridge; N.Y.: Cambridge University Press, 2012. ISBN 978-0-521-51814-7.
19. *Pimentel T., et al.* Deep Active Learning for Anomaly Detection. 2020. arXiv: 1805.09411 [cs, stat]. URL: <http://arxiv.org/abs/1805.09411> (visited on 08/30/2020).
20. *Das S., et al.* Incorporating Expert Feedback into Active Anomaly Discovery // 2016 IEEE 16th Int. Conf. on Data Mining (ICDM). 2016. P. 853–858. <https://doi.org/10.1109/ICDM.2016.0102>
21. *IBM Analytics.* ASUM Analytics Solutions Unified Method. 2015.
22. *Suo M., et al.* Data-Driven Fault Diagnosis of Satellite Power System Using Fuzzy Bayes Risk and SVM // *Aerospace Science and Technology*. 2019. V. 84. P. 1092–1105. ISSN 1270-9638. <https://doi.org/10.1016/j.ast.2018.11.049>
23. *Kononenko I.* Estimating Attributes: Analysis and Extensions of RELIEF // *Machine Learning: ECML-94/ Eds. F. Bergadano, L. De Raedt*. Berlin, Heidelberg: Springer, 1994. P. 171–182. (Lecture Notes in Computer Science.) ISBN 978-3-54048365-6. https://doi.org/10.1007/3-540-57868-4_57
24. *Hanchuan Peng, Fuhui Long, Ding C.* Feature Selection Based on Mutual Information Criteria of Max-Dependency, Max-Relevance, and Min-Redundancy // *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 2005. V. 27. No. 8. P. 1226–1238. ISSN 1939-3539. <https://doi.org/10.1109/TPAMI.2005.159>
25. *Hu Q., et al.* Neighborhood Rough Set Based Heterogeneous Feature Subset Selection // *Information Sciences*. 2008. V. 178. No. 18. P. 3577–3594. ISSN 0020-0255. <https://doi.org/10.1016/j.ins.2008.05.024>
26. *Mallat S.* A Wavelet Tour of Signal Processing: The Sparse Way. 3rd edition. Academic Press, 2008. ISBN 978-0-12-374370-1. <https://doi.org/10.1016/B978-0-12374370-1.X0001-8>
27. *Barreyre C., et al.* Statistical Methods for Outlier Detection in Space Telemetries // *Space Operations: Inspiring Humankind’s Future / Eds. H. Pasquier, et al.* Cham: Springer Int. Publishing, 2019. P. 513–547. ISBN 978-3-030-11536-4. https://doi.org/10.1007/978-3-030-11536-4_20
28. *O’Meara C., Schlag L., Wickler M.* Applications of Deep Learning Neural Networks to Satellite Telemetry Monitoring // 15th Int. Conf. on Space Operations. Marseille, France: AIAA, 2018. ISBN 978-1-62410-562-3. <https://doi.org/10.2514/6.2018-2558>
29. *Gowda G.M., et al.* The Added Value Of Advanced Feature Engineering And Selection For Machine Learning Models In Spacecraft Behavior Prediction // 2018 SpaceOps Conf. Marseille, France: AIAA, 2018. ISBN 978-1-62410-562-3. <https://doi.org/10.2514/6.2018-2561>
30. *Lucas L., Boumghar R.* Machine Learning for Spacecraft Operations Support — The Mars Express Power Challenge / 2017 6th Int. Conf. on Space Mission Challenges for Inf. Technology (SMC-IT). 2017. P. 82–87. <https://doi.org/10.1109/SMC-IT.2017.21>
31. *Bay S.D., Schwabacher M.* Mining Distance-Based Outliers in near Linear Time with Randomization and a Simple Pruning Rule // *Proc. 9th ACM SIGKDD Int. Conf. on Knowledge Discovery and Data Mining*. Washington, D.C.: ACM, 2003. P. 29–38. (KDD ’03). ISBN 978-1-58113-737-8. <https://doi.org/10.1145/956750.956758>
32. *Breunig M.M., et al.* LOF: Identifying Density-Based Local Outliers // *Proc. 2000 ACM SIGMOD Int. Conf. on Management of Data*. Dallas, Texas, USA: ACM, 2000. P. 93–104. (SIGMOD ’00). ISBN 978-1-58113-217-5. <https://doi.org/10.1145/342009.335388>

33. *Von Brünken J., Houle M.E., Zimek A.* Intrinsic Dimensional Outlier Detection in High-Dimensional Data // NII Technical Reports. 2015. V. 2015. No. 3. P. 1–12.
34. *Houle M.E., Kashima H., Nett M.* Generalized Expansion Dimension // 2012 IEEE 12th Int. Conf. on Data Mining Workshops. 2012. P. 587–594.
<https://doi.org/10.1109/ICDMW.2012.94>
35. *Houle M.E.* Dimensionality, Discriminability, Density and Distance Distributions // 2013 IEEE 13th Int. Conf. on Data Mining Workshops. 2013. P. 468–473.
<https://doi.org/10.1109/ICDMW.2013.139>
36. *Kriegel H.-P., et al.* Outlier Detection in Axis-Parallel Subspaces of High Dimensional Data // Adv. in Knowledge Discovery and Data Mining / Eds. T. Theeramunkong, et al. Berlin, Heidelberg: Springer, 2009. P. 831–838. (Lecture Notes in Computer Science). ISBN 978-3-642-01307-2.
https://doi.org/10.1007/978-3-642-01307-2_86
37. *Kriegel H.-P., Schubert M., Zimek A.* Angle-Based Outlier Detection in High-Dimensional Data // Proc. 14th ACM SIGKDD Int. Conf. on Knowledge Discovery and Data Mining. New York, NY, USA: ACM, 2008. P. 444–452. (KDD '08). ISBN 978-1-60558-193-4. <https://doi.org/10.1145/1401890.1401946>
38. *Rosenblatt M.* Remarks on Some Nonparametric Estimates of a Density Function // Annals of Mathematical Statistics. 1956. V. 27. No. 3. P. 832–837. ISSN 0003-4851, 2168-8990. <https://doi.org/10.1214/aoms/1177728190>
39. *Tang B., He H.* A Local Density-Based Approach for Outlier Detection // Neurocomputing. 2017. V. 241. P. 171–180. ISSN 0925-2312.
<https://doi.org/10.1016/j.neucom.2017.02.039>
40. Dynamic Time Warping // Inf. Retrieval for Music and Motion / Eds. M. Muller. Berlin, Heidelberg: Springer, 2007. P. 69–84. ISBN 978-3-540-74048-3.
https://doi.org/10.1007/978-3-540-74048-3_4
41. *O'Meara C., et al.* ATHMoS: Automated Telemetry Health Monitoring System at GSOC Using Outlier Detection and Supervised Machine Learning // SpaceOps 2016 Conf. Daejeon, Korea: AIAA, 2016. ISBN 978-1-62410-426-8.
<https://doi.org/10.2514/6.2016-2347>
42. *Martinez J.* New Telemetry Monitoring Paradigm with Novelty Detection // SpaceOps 2012 Conf. AIAA, 2012. (SpaceOps Conf.s).
<https://doi.org/10.2514/6.2012-1275123>
43. *Schlag L., O'Meara C., Wickler M.* Numerical Analysis of Automated Anomaly Detection Algorithms for Satellite Telemetry // 15th Int. Conf. on Space Operations. Marseille, France: AIAA, 2018. ISBN 978-1-62410-562-3.
<https://doi.org/10.2514/6.2018-2534>
44. *Guha S., Rastogi R., Shim K.* Rock: A Robust Clustering Algorithm for Categorical Attributes // Inf. Systems. 2000. V. 25. No. 5. P. 345–366. ISSN 0306-4379.
[https://doi.org/10.1016/S0306-4379\(00\)00022-3](https://doi.org/10.1016/S0306-4379(00)00022-3)
45. *Ertöz L., Steinbach M., Kumar V.* Finding Clusters of Different Sizes, Shapes, and Densities in Noisy, High Dimensional Data // Proc. 2003 SIAM Int. Conf. on Data Mining. Society for Industrial, Applied Mathematics, 2003. P. 47–58. (Proceedings). ISBN 978-0-89871-545-3. <https://doi.org/10.1137/1.9781611972733.5>
46. *Kohonen T.* Exploration of Very Large Databases by Self-Organizing Maps // Proc. of Int. Conf. on Neural Networks (ICNN'97). V. 1. IEEE, 1997. PL1-PL6.
<https://doi.org/10.1109/ICNN.1997.611622>
47. *He Z., Xu X., Deng S.* Discovering Cluster-Based Local Outliers // Pattern Recognition Letters. 2003. V. 24. No. 9. P. 1641–1650. ISSN 0167-8655.
[https://doi.org/10.1016/S0167-8655\(03\)00003-5](https://doi.org/10.1016/S0167-8655(03)00003-5)

48. *Sun H., et al.* CD-Trees: An Efficient Index Structure for Outlier Detection // Adv. in Web-Age Inf. Management / Eds. Q. Li, G. Wang, L. Feng. Berlin, Heidelberg: Springer, 2004. P. 600–609. (Lecture Notes in Computer Science). ISBN 978-3-540-27772-9. https://doi.org/10.1007/978-3-540-27772-9_60
49. *Iverson D.L., Field M.* Inductive System Health Monitoring. 2004.
50. *Iverson D.L., et al.* General Purpose Data-Driven Monitoring for Space Operations // J. of Aerospace Computing, Inf., and Communication. 2012. V. 9. No. 2. P. 26–44. <https://doi.org/10.2514/1.54964>
51. *Singh S.* A Data-Driven Approach to Cubesat Health Monitoring // Master's Theses and Project Reports. 2017. <https://doi.org/10.15368/theses.2017.100>
52. *Chen C., et al.* A Fault Diagnosis Method for Satellite Flywheel Bearings Based on 3D Correlation Dimension Clustering Technology // IEEE Access. 2018. V. 6. P. 78483–78492. ISSN 2169-3536. <https://doi.org/10.1109/ACCESS.2018.2885046>
53. *Suo M., et al.* Neighborhood Grid Clustering and Its Application in Fault Diagnosis of Satellite Power System // Proc. Inst. of Mech. Engineers, Part G: J. of Aerospace Engineering. 2019. V. 233. No. 4. P. 1270–1283. ISSN 0954-4100. <https://doi.org/10.1177/0954410017751991>
54. *Azevedo D.R., Ambrosio A.M., Vieira M.* Applying Data Mining for Detecting Anomalies in Satellites // 2012 9th European Dependable Computing Conf. 2012. P. 212–217. <https://doi.org/10.1109/EDCC.2012.19>
55. *Rahimi A., Kumar K.D., Alighanbari H.* Fault Estimation of Satellite Reaction Wheels Using Covariance Based Adaptive Unscented Kalman Filter // Acta Astronautica. 2017. V. 134. P. 159–169. ISSN 0094-5765. <https://doi.org/10.1016/j.actaastro.2017.02.003>
56. *Yairi T., et al.* A Data-Driven Health Monitoring Method for Satellite Housekeeping Data Based on Probabilistic Clustering and Dimensionality Reduction // IEEE Trans. on Aerospace and Electronic Systems. 2017. V. 53. No. 3. P. 1384–1401. ISSN 1557-9603. <https://doi.org/10.1109/TAES.2017.2671247>
57. *Tipping M.E., Bishop C.M.* Mixtures of Probabilistic Principal Component Analyzers // Neural Computation. 1999. V. 11. No. 2. P. 443–482. ISSN 0899-7667. <https://doi.org/10.1162/089976699300016728>
58. *Adnane A. et al.* Real-Time Sensor Fault Detection and Isolation for LEO Satellite Attitude Estimation through Magnetometer Data // Adv. Space Res. 2018. V. 61. No. 4. P. 1143–1157. ISSN 0273-1177. <https://doi.org/10.1016/j.asr.2017.12.007>
59. *Ahmed A.M., et al.* Prediction of Battery Remaining Useful Life on Board Satellites Using Logical Analysis of Data // 2019 IEEE Aerospace Conf. 2019. P. 1–8. <https://doi.org/10.1109/AERO.2019.8741717>
60. *Kaplan E.L., Meier P.* Nonparametric Estimation from Incomplete Observations // J. of the American Statistical Association. 1958. V. 53. No. 282. P. 457–481. ISSN 0162-1459. <https://doi.org/10.2307/2281868>. JSTOR: 2281868.
61. *Chung J., et al.* Empirical Evaluation of Gated Recurrent Neural Networks on Sequence Modeling. 2014. arXiv: 1412.3555 [cs]. URL: <http://arxiv.org/abs/1412.3555> (visited on 09/01/2020).
62. *Hochreiter S., Schmidhuber J.* Long Short-Term Memory // Neural Computation. 1997. <https://doi.org/10.1162/neco.1997.9.8.1735>
63. *Agrawal R., Imielinski T., Swami A.* Mining Association Rules between Sets of Items in Large Databases // ACM SIGMOD Record. 1993. V. 22. No. 2. P. 207–216. ISSN 0163-5808. <https://doi.org/10.1145/170036.170072>
64. *Schölkopf B., et al.* Estimating the Support of a High-Dimensional Distribution // Neural Computation. 2001. V. 13. No. 7. P. 1443–1471. ISSN 0899-7667. <https://doi.org/10.1162/089976601750264965>

65. *Das S., et al.* Multiple Kernel Learning for Heterogeneous Anomaly Detection: Algorithm and Aviation Safety Case Study // Proc. 16th ACM SIGKDD Int. Conf. on Knowledge Discovery and Data Mining. New York, NY, USA: ACM, 2010. P. 47–56. (KDD '10). ISBN 978-1-4503-0055-1. <https://doi.org/10.1145/1835804.1835813>
66. *Budalakoti S., Srivastava A.N., Otey M.E.* Anomaly Detection and Diagnosis Algorithms for Discrete Symbol Sequences with Applications to Airline Safety // IEEE Trans. on Systems, Man, and Cybernetics. Part C: Applications and Reviews. 2009. V. 39. No. 1. P. 101–113. ISSN 1094-6977. <https://doi.org/10.1109/TSMCC.2008.2007248>
67. *Patel P., et al.* Mining Motifs in Massive Time Series Databases // Proc. 2002 IEEE Int. Conf. on Data Mining, 2002. 2002. <https://doi.org/10.1109/ICDM.2002.1183925>
68. *Li K., et al.* A Spacecraft Electrical Characteristics Multi-Label Classification Method Based on Off-Line FCM Clustering and On-Line WPSVM // PLOS ONE. 2015. V. 10. No. 11. e0140395. ISSN 1932-6203. <https://doi.org/10.1371/journal.pone.0140395>.
69. *Li K., et al.* Multi-Label Spacecraft Electrical Signal Classification Method Based on DBN and Random Forest // PLoS ONE. 2017. V. 12. No. 5. ISSN 1932-6203. <https://doi.org/10.1371/journal.pone.0176614>. pmid: 28486479.
70. *Воронцов В.А., Федоров Е.А.* Разработка прототипа интеллектуальной системы оперативного мониторинга и технического состояния основных бортовых систем космического аппарата // Тр. Маи. 2015. № 82. С. 35. ISSN 1727-6942.
71. *Nassar B., Hussein W.* State-of-Health Analysis Applied to Spacecraft Telemetry Based on a New Projection to Latent Structure Discriminant Analysis Algorithm // 2015 IEEE Aerospace Conf. 2015. P. 1–11. <https://doi.org/10.1109/AERO.2015.7118887>
72. *Nassar B., Hussein W., Medhat M.* Supervised Learning Algorithms for Spacecraft Attitude Determination and Control System Health Monitoring // IEEE Aerospace and Electronic Systems Magazine. 2017. V. 32. No. 4. P. 26–39. ISSN 1557-959X. <https://doi.org/10.1109/MAES.2017.150049>
73. *Fuertes S., et al.* Improving Spacecraft Health Monitoring with Automatic Anomaly Detection Techniques // SpaceOps 2016 Conf. AIAA, 2016. <https://doi.org/10.2514/6.2016-2430>
74. *Galal M.A., et al.* Satellite Battery Fault Detection Using Naive Bayesian Classifier // 2019 IEEE Aerospace Conf. 2019. P. 1–11. <https://doi.org/10.1109/AERO.2019.8741963>
75. *Ibrahim S.K., et al.* Machine Learning Techniques for Satellite Fault Diagnosis // Ain Shams Engineering J. 2020. V. 11. No. 1. P. 45–56. ISSN 2090-4479. <https://doi.org/10.1016/j.asej.2019.08.006>
76. *Trafalis T.B., Ince H.* Support Vector Machine for Regression and Applications to Financial Forecasting // Proc. IEEE-INNS-ENNS Int. Joint Conf. on Neural Networks. IJCNN 2000. Neural Computing: New Challenges and Perspectives for the New Millennium. V. 6. IEEE, 2000. P. 348–353. <https://doi.org/10.1109/IJCNN.2000.859420>
77. *Chikalov I., et al.* Logical Analysis of Data: Theory, Methodology and Applications // Three Approaches to Data Analysis: Test Theory, Rough Sets and Logical Analysis of Data / Eds. I. Chikalov, et al. Berlin, Heidelberg: Springer, 2013. P. 147–192. (Intelligent Systems Reference Library). ISBN 978-3-642-28667-4. https://doi.org/10.1007/978-3-642-28667-4_3
78. *Абрамов Н.С. и др.* Высокопроизводительная нейросетевая система мониторинга состояния и поведения подсистем космических аппаратов по телеметрическим данным // Программные системы: теория и приложения. Россия, Вельсково, 2017. № 3 (30).

79. *Martinez J., Donati A.* Novelty Detection with Deep Learning // 2018 SpaceOps Conf. AIAA, 2018. (SpaceOps Conf.s). <https://doi.org/10.2514/6.2018-2560>
80. *Petkovic M., et al.* Machine Learning for Predicting Thermal Power Consumption of the Mars Express Spacecraft // IEEE Aerospace and Electronic Systems Magazine. 2019. V. 34. No. 7. P. 46–60. ISSN 1557-959X. <https://doi.org/10.1109/MAES.2019.2915456>
81. *Ibrahim S.K., et al.* Machine Learning Methods for Spacecraft Telemetry Mining // IEEE Trans. on Aerospace and Electronic Systems. 2019. V. 55. No. 4. P. 1816–1827. ISSN 1557-9603. <https://doi.org/10.1109/TAES.2018.2876586>
82. *Omran E.A., Murtada W.A.* Efficient Anomaly Classification for Spacecraft Reaction Wheels // Neural Computing and Applications. 2019. V. 31. No. 7. P. 2741–2747. ISSN 1433-3058. <https://doi.org/10.1007/s00521-017-3226-y>
83. *Murtada W.A., Omran E.A.* Robust Anomaly Identification Algorithm for Noisy Signals: Spacecraft Solar Panels Model // Neural Computing and Applications. 2019. ISSN 0941-0643, 1433-3058. <https://doi.org/10.1007/s00521-019-04407-2>
84. *Shin Y., et al.* ITAD: Integrative Tensor-Based Anomaly Detection System for Reducing False Positives of Satellite Systems // Proc. 29th ACM Int. Conf. on Inf. & Knowledge Management. New York, NY, USA: ACM, 2020. P. 2733–2740. (CIKM '20). ISBN 978-1-4503-6859-9. <https://doi.org/10.1145/3340531.3412716>
85. *Kiers H.A.L.* Towards a Standardized Notation and Terminology in Multiway Analysis // J. of Chemometrics. 2000. V. 14. No. 3. P. 105–122. ISSN 1099-128X. [https://doi.org/10.1002/1099-128X\(200005/06\)14:3<105::AID-CEM582>3.0.CO;2-I](https://doi.org/10.1002/1099-128X(200005/06)14:3<105::AID-CEM582>3.0.CO;2-I).
86. *Hundman K., et al.* Detecting Spacecraft Anomalies Using LSTMs and Nonparametric Dynamic Thresholding // Proc. ACM SIGKDD Int. Conf. on Knowledge Discovery and Data Mining. 2018. P. 387–395. <https://doi.org/10.1145/3219819.3219845>
87. *Pilastre B., et al.* Anomaly Detection in Mixed Telemetry Data Using a Sparse Representation and Dictionary Learning // Signal Processing. 2020. V. 168. P. 107320. ISSN 0165-1684. <https://doi.org/10.1016/j.sigpro.2019.107320>
88. *Aggarwal C.C.* Outlier Ensembles: Position Paper // ACM SIGKDD Explorations Newsletter. 2013. V. 14. No. 2. P. 49–58. ISSN 1931-0145. <https://doi.org/10.1145/2481244.2481252>
89. *Carlton A., et al.* Telemetry Fault-Detection Algorithms: Applications for Spacecraft Monitoring and Space Environment Sensing // J. of Aerospace Inf. Systems. 2018. V. 15. No. 5. P. 239–252. <https://doi.org/10.2514/1.1010587>
90. *Nozari H.A., et al.* Novel Non-Model-Based Fault Detection and Isolation of Satellite Reaction Wheels Based on a Mixed-Learning Fusion Framework // IFAC PapersOnLine. 2019. V. 52. No. 12. P. 194–199. (21st IFAC Symposium on Automatic Control in Aerospace ACA 2019). ISSN 2405-8963. <https://doi.org/10.1016/j.ifacol.2019.11.222>
91. *Pang J., et al.* Anomaly Detection for Satellite Telemetry Series with Prediction Interval Optimization // 2018 Int. Conf. on Sensing, Diagnostics, Prognostics, and Control (SDPC). 2018. P. 408–414. <https://doi.org/10.1109/SDPC.2018.8664879>
92. *Lavin A., Ahmad S.* Evaluating Real-Time Anomaly Detection Algorithms – The Numenta Anomaly Benchmark // 2015 IEEE 14th Int. Conf. on Machine Learning and Applications (ICMLA). 2015. P. 38–44. <https://doi.org/10.1109/ICMLA.2015.141>
93. *Tatbul N., et al.* Precision and Recall for Time Series // Adv. in Neural Inf. Processing Systems 31 / Eds. S. Bengio, et al. Curran Associates, Inc., 2018. P. 1920–1930.

94. *Verzola I., et al.* Project Sibyl: A Novelty Detection System for Human Spaceflight Operations // SpaceOps 2016 Conf. AIAA, 2016. (SpaceOps Conf.)
<https://doi.org/10.2514/6.2016-2405>
95. ELKI Data Mining Framework. URL: <https://elki-project.github.io/> (дата обр. 02.11.2020).
96. *European Space Agency.* GOCE Telemetry Data Collection. 2019.
<https://doi.org/10.5270/esa-7nc8pjp>
97. *Ganin Y., et al.* Domain-Adversarial Training of Neural Networks // J. of Machine Learning Research. 2016. V. 17. No. 59. P. 1–35.
98. *Von Rueden L., et al.* Informed Machine Learning — A Taxonomy and Survey of Integrating Knowledge into Learning Systems. 2020. arXiv: 1903.12394 [cs, stat]. URL: <http://arxiv.org/abs/1903.12394> (visited on 09/04/2020).
99. *Fink O., et al.* Potential, Challenges and Future Directions for Deep Learning in Prognostics and Health Management Applications // Eng. Appl. Artif. Intell. 2020.
<https://doi.org/10.1016/j.engappai.2020.103678>

Статья представлена к публикации членом редколлегии В.М. Глузовым.

Поступила в редакцию 04.12.2020

После доработки 04.01.2021

Принята к публикации 16.03.2021