

Методика обнаружения отказов сложных технических систем на основе алгоритмов машинного обучения

А.С. Гоголевский^{1а}, А.В. Романов^{1б}, Р.Е. Трепков^{1с}, В.А. Соколова^{2д}

¹Военно-космическая академия им. А.Ф. Можайского, ул. Ждановская, 13, Санкт-Петербург, Россия

²Санкт-Петербургский государственный лесотехнический университет им. С.М. Кирова, Институтский пер., 5, Санкт-Петербург, Россия

^а gogolevski@bk.ru, ^б romanich-87@mail.ru, ^с romanprio@mail.ru, ^д sokolova_vika@inbox.ru

^а <https://orcid.org/0000-0002-1279-013X>,

^б <https://orcid.org/0000-0001-6571-5558>,

^с <https://orcid.org/0000-0003-4154-0786>,

^д <https://orcid.org/0000-0001-6880-445X>

Статья поступила 07.10.2019, принята 08.11.2019

Характерной особенностью современного развития сложных технических систем (СТС) является широкое внедрение методов и средств автоматизированного управления, а также применение СТС в экстремальных условиях эксплуатации и обслуживания. В результате снижается надежность СТС, что приводит к увеличению доли эксплуатационных затрат по сравнению с общими затратами на проектирование, производство и применение этих систем. Кроме того, отказы в СТС имеют различные негативные последствия — потерю информации, простой сопряженных с СТС других устройств и систем, аварии и т. д. Очевидно, что в условиях медленно протекающей модернизации единственной возможностью поддержания работоспособности оборудования и сложной технической системы в целом является своевременная оценка состояния системы на этапе ее эксплуатации с целью своевременного и всестороннего анализа происходящих технологических процессов, диагностики состояния и прогнозирования поведения. В статье предлагается методика обнаружения отказов на основе алгоритмов машинного обучения, которая позволяет решить данную проблему.

Ключевые слова: машинное обучение; метод опорных векторов; сложные технические системы.

Methods of detecting failures in complex technical systems based on machine learning algorithms

A.S. Gogolevsky^{1а}, A.V. Romanov^{1б}, R.E. Trepkov^{1с}, V.A. Sokolova^{2д}

¹Military Space Academy under name of A.F. Mozhaisky; 13, Zhdanovskaya St., St. Petersburg, Russia

²St. Petersburg State Forest Technical University under name of S.M. Kirov; 5, Institutsky Per., St. Petersburg, Russia

^а gogolevski@bk.ru, ^б romanich-87@mail.ru, ^с romanprio@mail.ru, ^д sokolova_vika@inbox.ru

^а <https://orcid.org/0000-0002-1279-013X>,

^б <https://orcid.org/0000-0001-6571-5558>,

^с <https://orcid.org/0000-0003-4154-0786>,

^д <https://orcid.org/0000-0001-6880-445X>

Received 07.10.2019, accepted 08.11.2019

A characteristic feature of the modern development of complex technical systems (CTS) is the widespread introduction in their methods and means of automated control, as well as the use of CTS in extreme conditions of operation and maintenance. As a result, the reliability of the CTS is reduced, which leads to an increase in the share of operating costs compared with the total cost of designing, manufacturing and using these systems. In addition, failures in the CTS lead to various kinds of consequences: information loss, downtime of other devices and systems associated with the CTS, accidents, etc. In addition, in the conditions of a slowly proceeding modernization, the only way to maintain the operability of the equipment and the complex technical system as a whole is a timely assessment of the state of the system at the stage of its operation with the goal of timely and comprehensive analysis of the processes, diagnostics of the state and prediction of behavior. The article proposes a technique for detecting failures based on machine learning algorithms that will solve this problem.

Keywords: machine learning; support vector machine; complex technical systems.

Введение. В век информационных технологий достоверность результатов измерений, получаемых от аппаратуры диагностики, в сложных технических сис-

темах (СТС), безусловно, играет важную роль и определяет их качество. Как правило, измерения, поступающие в СТС, содержат помехи двух типов — высокого

уровня (выбросы и пропадания сигнала) и низкого уровня (инструментальные и иные погрешности). Они приводят к неправильной работе СТС или отказу всей системы в целом [1; 2].

Наличие в измерениях помех высокого уровня приводит к тому, что выборочная совокупность измерений не может быть отнесена к разряду нормально распределенных случайных процессов.

Для исключения этого класса помех используют методы робастной локальной регрессии, медианную фильтрацию и широкий набор методик статистического анализа случайных процессов [2; 3].

Однако представленные методы прекрасно работают, когда известен весь динамический ряд. А для решения задач сглаживания или фильтрации некоторого измерения x_i этого ряда может быть выбрано окно $[x_i-d, x_i+d]$ произвольной длины d , к которому может быть применен тот или иной метод.

В системах реального времени, к которым относятся сложные технические системы, данные подходы малоприменимы, так как данные от датчиков с некоторым шагом дискретизации передаются по каналам связи в обрабатывающий узел, и в каждый момент времени состояние динамической системы представлено не всем динамическим рядом, а только выборочной совокупностью предыдущих измерений [4].

Кроме этого, существует сложность в подборе функции распределения для выборочной совокупности с целью вычисления доверительных интервалов и проверки значимости статистических критериев. Она заключается в том, что данный процесс является временемким, что для СТС реального времени является недопустимой роскошью.

В этих условиях разработка методики обнаружения отказов на основе статистических методов машинного обучения является актуальной, так как она позволит выполнять предварительную фильтрацию исходных измерений более качественно и за короткое время.

Анализ методов машинного обучения. В результате анализа существующих статистических методов обнаружения аномальных измерений [5–16] выяснилось следующее:

1. Все методы машинного обучения хорошо работают, когда известен весь ряд значений. В СТС в каждый момент времени ее состояние представлено не всем динамическим рядом, а только выборочной совокупностью предыдущих измерений.

2. Существует сложность в подборе функции распределения для выборочной совокупности с целью вычисления доверительных интервалов и проверки значимости статистических критериев.

При анализе методов фильтрации было установлено, что они имеют ряд недостатков: для сглаживания или фильтрации некоторой точки используются все

данные измерения; требуется идентификация аномалий (отказов), т. е. точное их определение.

В результате в качестве основы метода обнаружения отказов и методики в целом был выбран метод опорных векторов, так как:

- наиболее эффективен при двухклассовой классификации. Это наиболее быстрый метод нахождения решающих функций;

- метод наиболее эффективен на средних и малых выборках;

- метод сводится к решению задачи квадратичного программирования в выпуклой области, которая всегда имеет единственное решение;

- при выборе нелинейной ядровой функции дает возможность решать сложные задачи с плохо разделяемыми классами;

- метод находит разделяющую полосу максимальной ширины, что позволяет в дальнейшем осуществлять более уверенную классификацию.

Постановка задачи обнаружения отказов сложных технических систем. Для наглядности разрабатываемой методики проанализируем один измеряемый параметр, а именно данные, поступающие с датчика угловой скорости.

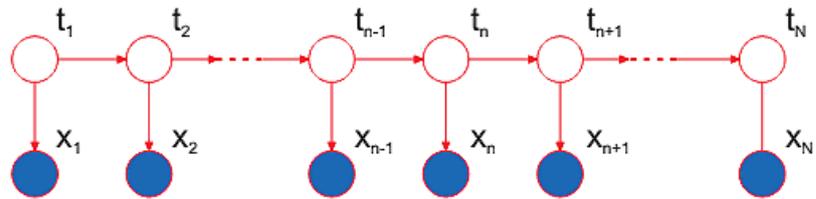


Рис. 1. Графическая модель сема данных с датчика угловой скорости

На рис. 1 представлено графическое представление процесса получения данных с датчика угловой скорости.

Пусть имеется множество $X(t)$, которое является данными измерений угловой скорости за определенный период времени T .

Для проведения статистического анализа перенесем результаты измерений на числовую ось.

Также выделим множество значений, по которым будем разрабатывать и тестировать новый метод обнаружения аномальных измерений. Далее данное множество будем называть обучающей выборкой, а все остальные данные будут применены для проверки разработанного метода (рис. 2).

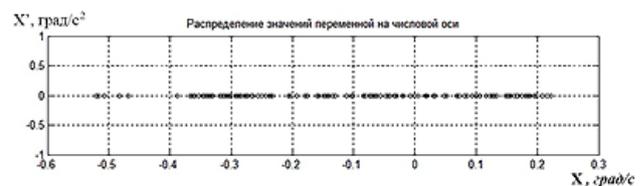


Рис. 2. Обучающая выборка на числовой оси относительно времени

Каждая точка (состояние СТС) имеет параметр угловой скорости X , отложенный по оси абсцисс. Каждое измерение состояния СТС имеет строгую последовательность относительно времени t , т. е.

измерения происходят с определенным шагом. В нашем случае рассматривается процесс съема измерений с датчика угловой скорости с одинаковым шагом.

Требуется разработать метод, позволяющий идентифицировать аномальные измерения (отказы) в новых данных.

Постановка задачи одноклассовой классификации. В соответствии с формальной постановкой задачи требуется разработать эффективный метод обнаружения отказов на основе алгоритмов статистического анализа, а именно на основе метода опорных векторов, который станет основой методики.

Под задачей обнаружения отказов (аномальных измерений) подразумевается задача одноклассовой классификации [6; 14; 17; 18].

Задача обнаружения аномальных измерений заключается в идентификации новых данных относительно исходных. Другими словами, требуется определить, относятся ли новые данные к области нормальных (достоверных) измерений или нет.

Пусть имеется обучающая выборка $\mathbf{x}_1(t), \dots, \mathbf{x}_n(t) \subset X$, где $\mathbf{x}(t)$ — состояние СТС в определенный момент времени; n — количество состояний в обучающей выборке; X — множество состояний за определенный период времени, его также можно обозначить как подмножество R^m .

С целью наглядности разрабатываемого метода в рассматриваемом случае состояние системы характеризуется одним измеряемым параметром. Также, основываясь на [14; 15], обучающая выборка должна иметь малую длину.

В соответствии с известными работами [6; 14; 15], метод обнаружения аномальных измерений подразумевает определение функции f (представляет собой гиперплоскость). В рамках нашей задачи для двумерного пространства она представляет собой разделяющую прямую.

Функция f принимает значение «+1», если измерение имеет нормальные значения, и «-1» — аномальное измерение (отказ).

Основной проблемой решения данной функции является то, что в большинстве случаев она должна быть нелинейной [16].

Методика обнаружения отказов сложных технических систем.

1. Получение дополнительной информации о системе.

Основной подход заключается в следующем: чтобы получить дополнительную информацию об СТС, нужно произвести анализ данной системы в фазовом пространстве [19].

Согласно физическому энциклопедическому словарю [20], фазовое пространство или полное фазовое пространство представляет собой геометрический образ, представленный множеством всевозможных состояний физической системы.

Основные свойства фазового пространства формулируются так [20]:

1. Время не является одной из координат фазового пространства. Течению времени соответствует перемещение фазовой точки по фазовой траектории;

2. Через каждую точку проходит одна и только одна фазовая траектория.

Сформулируем правило получения дополнительной информации.

Для наглядности рассмотрим процесс съема показаний угловой скорости $X(t)$.

Предполагается, что процесс съема показаний измерений угловой скорости имеет следующий вид:

$$X(t) = x(t) + \varepsilon(t) . \tag{1}$$

В этом соотношении $x(t)$ — истинное значение измеряемого параметра, а величина $\varepsilon(t)$ представляет случайную составляющую, которая моделирует искажения (помеха).

Измерения проводятся в определенные моменты времени: $t_1, t_2, \dots, t_i, \dots, t_n$, образуя строгую последовательность. Таким образом, в каждый i -й момент времени процесс представлен выборочной совокупностью предыдущих измерений.

Основная идея правила заключается в том, чтобы состояние системы с n -параметрами в фазовом пространстве дополнить еще и другими параметрами, а именно приращениями данных параметров [19].

В результате фазовое пространство будет представлять собой множество параметров X_i в определенный момент времени и приращения данных параметров: $dX_i = X_i - X_{i-1}$ (рис. 3).

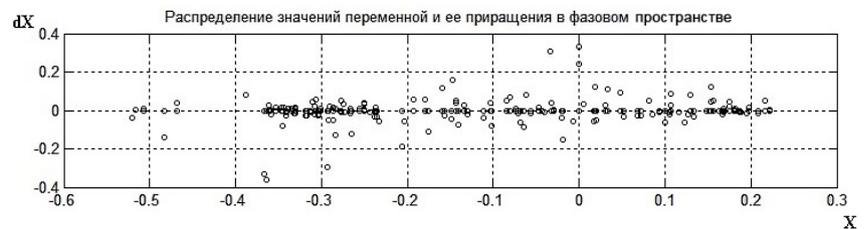


Рис. 3. Множество значений измерений состояния СТС в фазовом пространстве

В общем виде при меняющемся шаге измерения приращение рассчитывается по формуле $dX_i = \frac{X_i - X_{i-1}}{h}$, где h — шаг измерения.

В нашем случае точка, изображающая состояние СТС в фазовом пространстве и характеризующаяся одним параметром — угловой скоростью, принадлежит некоторой кривой, называемой фазовой траекторией (ФТ) [19; 20].

Исходя из свойств фазового пространства [20], данная ФТ образует геометрический образ — фазовое пространство, заполненное непересекающимися фазовыми траекториями, которое называется фазовым портретом системы (рис. 4) [20].



Рис. 4. Фазовый портрет СТС с одним измеряемым параметром

На рис. 4 по оси абсцисс отложены показания угловой скорости, а по оси ординат — показания приращений. Показания угловой скорости, обозначенные красными точками на рис. 4, относительно предыдущих, обозначенных зелеными точками, явно указывают на резкое изменение параметра. Вследствие этого изменяется приращение параметра в данный момент времени. Это дает нам право считать, что приращения параметров можно использовать как один из параметров системы в целом.

Таким образом, в фазовом пространстве получаем дополнительную информацию об измерениях. В свою очередь, это дает право применять методы статистического анализа для обнаружения отказов СТС.

С этой целью каждый параметр системы в фазовом пространстве описывается двумя переменными: собственно значением измерения на каждом шаге и значением приращения данного измерения на данном шаге.

2. Модель обнаружения аномалий Шелкопфа.

Стандартная модель обнаружения аномальных измерений Шелкопфа [16; 21] подразумевает определение параметрической функции f , которая принимает значение «+1» в небольшой области, покрывающей большинство точек обучающей выборки, и «-1» вне этой области.

В связи с тем, что в работе рассматривается система, в которой функция f является нелинейной, этот факт существенно затрудняет ее определение и вычисление ее параметров.

Основная идея метода заключается в отображении точек (состояния системы в определенный момент времени) обучающей выборки в некоторое пространство G (рис. 5), в котором разделяющая функция f становится линейной. Такое отображение также называется спрямляющим [16].

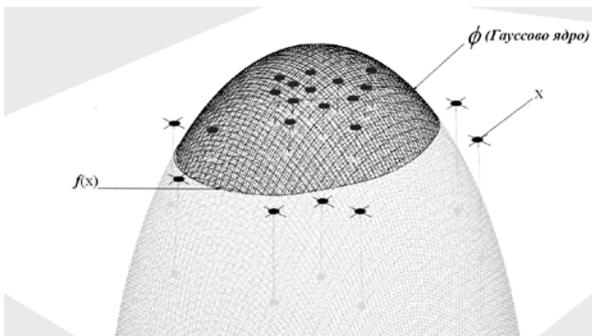


Рис. 5. Отображение точек обучающей выборки в спрямляющем пространстве G

Пусть имеется обучающая выборка $\mathbf{x}_1, \dots, \mathbf{x}_n \subset X$, где \mathbf{x}_i — вектор состояния СТС с двумя параметрами (измеряемый параметр и его приращение); n — количество измерений в обучающей выборке в фазо-

вом пространстве; X — множество состояний СТС, также его можно представить в виде компактного подмножества \mathbb{R}^n .

Пусть ϕ — такое отображение состояний системы $X \rightarrow G$, при котором точки обучающей выборки отображаются в пространство признаков большей размерности G .

В задачах одноклассовой классификации отображение ϕ обычно переводит пространство-образ в часть сферы с центром в точке $0 \in G$ [16].

Для построения отображения ϕ может использоваться произвольное ядро Мерсера $K(\mathbf{x}, \mathbf{y}) = (\phi(\mathbf{x}), \phi(\mathbf{y}))$. Существуют несколько типов ядер, однако в ряде работ [21; 22] предпочтение отдается, по ряду причин, гауссову ядру в связи с его эффективностью. Гауссово ядро имеет вид:

$$K(\mathbf{x}, \mathbf{y}) = \exp(-\sigma \cdot \|\mathbf{x} - \mathbf{y}\|^2). \quad (2)$$

Здесь σ — параметр ядра, определяющий геометрическую структуру выборки в пространстве G и принимающий значение $\sigma > 0$.

В работе [21] отмечается, что задача выбора подходящего параметра σ является чрезвычайно важной. Если используются очень малые значения параметра $1/\sigma \rightarrow 0$, то $K(\mathbf{x}, \mathbf{y}) \rightarrow 0$, тогда и точки в пространстве признаков стремятся быть ортогональными друг к другу, несмотря на их принадлежность нормальным или аномальным измерениям.

Иначе говоря, расстояние между ними становится очень большим, независимо от того, как они располагались в исходном пространстве X , что не позволяет их разделить. С другой стороны, когда используются большие значения $1/\sigma \rightarrow \infty$, $K(\mathbf{x}, \mathbf{y}) \rightarrow 1$, и все отображенные точки сводятся к одной точке. Очевидно, что такой подход также не может быть использован. Поэтому выбор параметра σ производится эмпирическим методом.

Введем параметр $\nu \in [0; 1]$, который обозначает долю нормальных данных обучающей выборки, для которых выполняется условие $\langle \mathbf{w}, \phi(\mathbf{x}) \rangle \geq \rho$.

Для разделения данных необходимо решить задачу квадратичной оптимизации:

$$\min_{\mathbf{w}, \xi_i, \rho} \left(\frac{1}{2} \|\mathbf{w}\|^2 + \frac{1}{\nu n} \sum_{i=1}^n \xi_i - \rho \right), \quad (3)$$

при ограничениях:

$$\begin{aligned} \langle \mathbf{w}, \phi(\mathbf{x}_i) \rangle &\geq \rho - \xi_i, \\ \xi_i &\geq 0, \quad i = 1, \dots, n. \end{aligned}$$

Принятие решения осуществляется на основе решающей функции:

$$g(\mathbf{x}, \mathbf{w}, \rho) = \text{sgn}(f(\mathbf{x}, \mathbf{w})) = \text{sgn}(\langle \mathbf{w}, \phi(\mathbf{x}) \rangle - \rho), \quad (4)$$

которая положительна в области нормальных измерений.

Используя множители Лагранжа $\alpha_i, \beta_i \geq 0$, запишем лагранжиан:

$$L(\mathbf{w}, \xi, \rho, \alpha, \beta) = \frac{1}{2} \|\mathbf{w}\|^2 + \frac{1}{vn} \sum_{i=1}^n \xi_i - \rho - \sum_{i=1}^n \alpha_i (\langle \mathbf{w}, \phi(\mathbf{x}_i) \rangle - \rho + \xi_i) - \sum_{i=1}^n \beta_i \cdot \xi_i. \quad (5)$$

В результате несложных преобразований и вычислений производных по переменным \mathbf{w}, ρ, ξ_i получаем двойственную задачу квадратичной оптимизации в виде:

$$\min_{\alpha} \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \alpha_i \cdot \alpha_j \cdot K(\mathbf{x}_i, \mathbf{x}_j), \quad (6)$$

при ограничениях:

$$0 \leq \alpha_i \leq \frac{1}{vn}, \quad \sum_{i=1}^n \alpha_i = 1.$$

Значение ρ вычисляется для любого j от 1 до n как:

$$\rho = (\langle \mathbf{w}, \phi(\mathbf{x}_j) \rangle) = \sum_{i=1}^n \alpha_i K(\mathbf{x}_i, \mathbf{x}_j). \quad (7)$$

После подстановки полученного решения в выражение для решающей функции g получаем:

$$g(\mathbf{x}, \mathbf{w}, \rho) = \text{sgn} \left(\sum_{i=1}^n \alpha_i K(\mathbf{x}_i, \mathbf{x}) - \rho \right). \quad (8)$$

Возникает еще одна проблема — выбор длины n обучающей выборки, которая решается эмпирическим путем.

3. Выбор параметра σ предложенного метода.

Принятие решения по оптимальным параметрам ядра и размеру окна осуществлялось с помощью алгоритма скользящего контроля, или кросс-валидации [23].

В работе применяется поэлементная кросс-валидация. В кросс-валидации применяются относительные коэффициенты ошибок классификации, которая вычисляется по формуле:

$$ACC = \frac{N_+}{N}, \quad (9)$$

где ACC — доля правильности классификации; N_+ — количество правильно классифицированных тестовых данных; N — общее количество тестовой выборки.

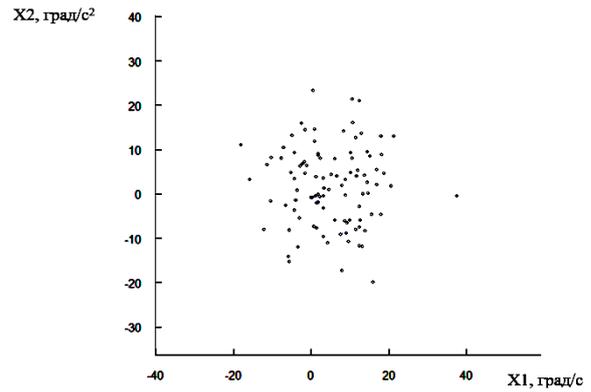
Выбор поэлементной кросс-валидации объясняется тем, что для СТС требуется точная настройка используемой в ней математической модели из-за применения ее на ограниченной обучающей выборке.

3.1 Выбор параметра Гауссова ядра.

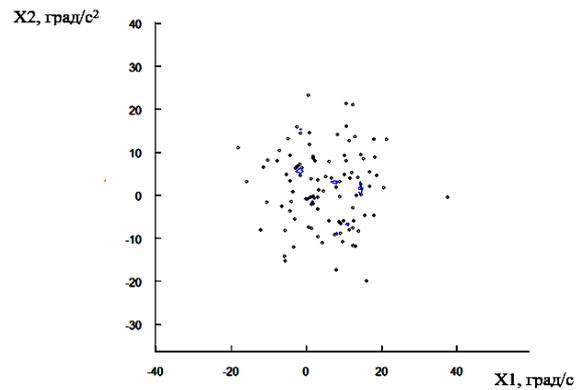
В результате проведения анализа с учетом факторов внешней среды выбран параметр C равный 0,8 [24].

Была сгенерирована модельная обучающая выборка $\mathbf{x}_1, \dots, \mathbf{x}_n \subset X$ с $n = 100$, где n — число состояний. После преобразования данных в фазовое пространство каждое состояние системы имеет вид $\mathbf{x}_i = \{x_i^1, x_i^2\}$, где x_i^1 — показания параметра системы, а x_i^2 — приращение данного параметра.

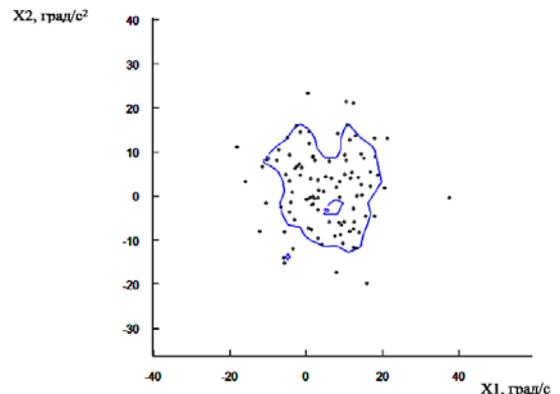
В результате моделирования были выбраны семь значений, которые изображены на рис. 6 (a..f) в диапазоне [0,9; 0,005]: 0,9(a); 0,3(b); 0,1(c); 0,07(d); 0,05(e); 0,01(f); 0,005(g). Синий контур на рисунках обозначает разделяющую функцию $f(\mathbf{x}, \mathbf{w})$. Он обводит область нормальных значений в зависимости от параметра ядра σ .



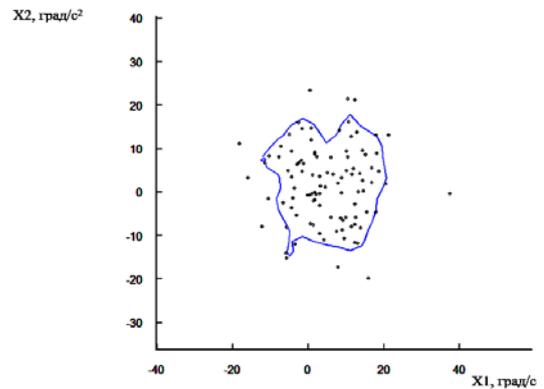
a) $\sigma = 0,9$



b) $\sigma = 0,3$

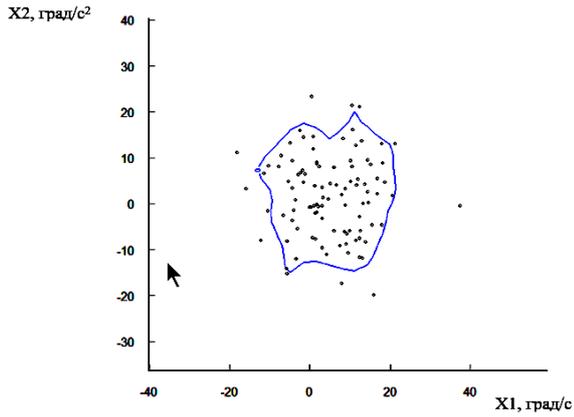


c) $\sigma = 0,1$

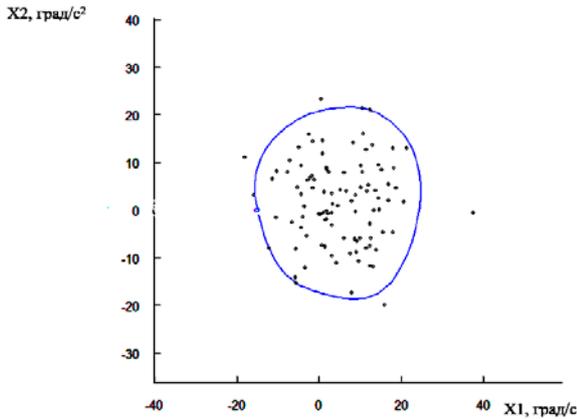


d) $\sigma = 0,07$

Рис. 6a–d. Визуальное представление решения задачи обнаружения аномальных измерений для модельной обучающей выборки



e) $\sigma = 0,05$



f) $\sigma = 0,01$

Рис. 6e, f. Визуальное представление решения задачи обнаружения аномальных измерений для модельной обучающей выборки

В табл. 1 представлены результаты моделирования разработанного метода машинного обучения с помощью алгоритма кросс-валидации LOO. Выбор параметра σ осуществляется по максимальному значению LOO и принимает значение 0,07.

В результате исследований были установлены следующие закономерности:

1. При возрастании σ область нормальных измерений уменьшается и разбивается на множество областей. При максимальных значениях данные области образуют точку. Получается эффект кластеризации;
2. При уменьшении σ область нормальных измерений увеличивается и в итоге охватывает всю область X.

Таблица 1

Результаты анализа разработанного метода машинного обучения с помощью алгоритма кросс-валидации LOO для нахождения оптимального параметра σ

σ	0,9	0,3	0,1	0,07	0,05	0,01
ACC _{LOO}	0,501	0,545	0,686	0,717	0,69	0,687

3.2 Определение обучающего окна.

В результате анализа функционирования СТС и условий ее эксплуатации для окна были выбраны следующие значения: 30, 50, 100, 200.

Были сгенерированы обучающие выборки $x_1, \dots, x_n \in X$ с $n = 30, 50, 100, 200$, где n — число состояний. После преобразования данных в фазовое пространство каждое состояние системы имеет вид $x_i = \{x_i^1, x_i^2\}$, где x_i^1 — показания параметра динамической системы, а x_i^2 — приращение данного параметра.

В табл. 2 представлены результаты анализа разработанного метода машинного обучения с помощью алгоритма кросс-валидации LOO, при этом учитывается скорость обучения системы с помощью нового метода обнаружения аномальных измерений.

Таблица 2

Результаты анализа для выбора оптимального размера обучающего окна

N	30	50	100	200
ACC _{LOO}	0,308	0,715	0,717	0,791
t _{обуч} , с	0,7	0,9	0,9	4

Выбор окна осуществляется по максимальному значению LOO и оптимальному выбору времени обучения и принимает значения 100.

Заключение. Разработана методика обнаружения отказов сложных технических систем на основе алгоритмов машинного обучения, которая позволяет произвести обнаружение аномальных измерений и рационально оценивать состояния СТС в целом. Остается проблема неопределенности в обучающей выборке, которая вызвана тем, что измеряемые параметры имеют строгую последовательность, зависящую от времени, с определенным шагом измерения. Сами измерения (параметры) снимаются с устройств, которые имеют точностную характеристику, т. е. имеют погрешность. Также обучающая выборка имеет малую размерность. Из этого следует, что каждый параметр состояния системы имеет неточную величину. В свою очередь, это приводит к тому, что вектор признаков (параметров) является неточным.

Для решения данной проблемы в дальнейшем предлагается модификация разработанной методики, а именно использование в ней робастной статистической модели, основанной на робастной модели ϵ — засорения.

Литература

1. Грибанов Д.Д. Общая теория измерений: моногр. М.: НИЦ Инфра-М, 2015. 116 с.
2. Мироновский Л.А., Слаев В.А. Алгоритмы оценивания результата трех измерений. СПб.: Проффессионал, 2010. 192 с.
3. Шуленин В.П. Робастные методы математической статистики. Томск: Изд-во НТЛ, 2016. 260 с.
4. Прокопенко А.В., Русаков М.А., Царев Р.Ю. Синтез систем реального времени с гарантированной доступностью программно-информационных ресурсов: моногр. Красноярск: Сиб. федер. ун-т, 2013. 92 с.
5. Бессмертный И.А. Искусственный интеллект. СПб.: СПбГУ ИТМО, 2010. 132 с.

6. Вапник В.Н., Червоненкис А.Я. Теория распознавания образов. М.: Наука, 1974. 416 с.
7. Вероятность и математическая статистика: энцикл. / под ред. Ю.В. Прохорова. М.: Большая российская энциклопедия, 2003. 910 с.
8. Гоголевский А.С. Нечеткая байесовская регрессионная модель с зависимыми переменными / ЛЭТИ // Материалы междунар. конф. по мягким вычислениям и измерениям. СПб., 2011. С. 205–208.
9. Гоголевский А.С. Разработка методов и моделей классификации различных объектов лесных систем при ограниченной обучающей выборке / РГГМУ // Сборник тез. шестнадцатой С.-Петербур. Ассамблеи молодых ученых и специалистов. СПб., 2011. С. 198–200.
10. Гоголевский А.С., Илющенко В.В. Анализ методов линейной классификации при ограниченной обучающей выборке применительно задачам лесного комплекса // Леса России в XXI веке: сб. материалов междунар. науч.-практ. интернет-конф., окт., 2010 г. СПб., 2010. С. 209–211.
11. Гоголевский А.С., Уткин Л.В. Метод опорных векторов в задаче классификации объектов лесных систем / ВоГТУ // Актуальные проблемы развития лесного комплекса: материалы междунар. науч.-техн. конф. Вологда, 2011. С. 3–5.
12. Головкин В.А. Нейронные сети: обучение, организация и применение. М.: ИПР-ЖР, 2001. 256 с.
13. Журавлев Ю.И., Рязанов В.В., Сенько О.В. «Распознавание». Математические методы. Программная система. Практические применения. М.: Фазис, 2006. 159 с.
14. Вьюгин В.В. Математические основы теории машинного обучения и прогнозирования. М., 2013. 387 с.
15. Новейшие методы обработки изображений / под ред. А. А. Потапова. М.: Физматлит, 2008. 496 с.
16. Мерков А.Б. Введение в методы статистического обучения. М.: Эдиториал УРСС, 2011. 256 с.
17. Афанасьев А.П., Дзюба С.М. Элементарное введение в теорию экстремальных задач. М.: Изд-во МФТИ, 2008. 186 с.
18. Гоголевский А.С. Интеллектуальная система обнаружения аномальных измерений на основе одноклассовой классификации / РГГМУ // Сборник тез. 17-й С.-Петербур. Ассамблеи молодых ученых и специалистов. СПб., 2012. С. 198–200.
19. Гоголевский А.С. Метод преобразования данных для обнаружения аномального поведения системы / ЛЭТИ // Материалы междунар. конф. по мягким вычислениям и измерениям. СПб., 2013. С. 164–166.
20. Физический энциклопедический словарь / гл. ред. А.М. Прохоров. М.: Сов. энциклопедия, 1984. 944 с.
21. Schölkopf B., Smola A.J. Learning with Kernels. MIT Press, 2002.
22. Wasserman L. All of Nonparametric Statistics. Springer, New York, 2006.
23. Mullin M., Sukthankar R. Complete Cross-Validation for Nearest Neighbor Classifiers // Proceedings of International Conference on Machine Learning. 2000. P. 1137–1145.
24. Джонсон Н., Лион Ф. Статистика и планирование эксперимента в технике и науке. Методы обработки данных: пер. с англ. М.: Мир, 1980. 611 с.
3. Shulenin V.P. Robust methods for processing measurement results. Tomsk: Izd-vo NTL, 2016. 260 p.
4. Prokopenko A.V., Rusakov M.A., Carev R.Yu. Synthesis of real-time systems with guaranteed availability of software and information resources: monogr. Krasnoyarsk: Sib. feder. un-t, 2013. 92 p.
5. Bessmertnyj I.A. Artificial intelligence. SPb.: SPbGU ITMO, 2010. 132 p.
6. Vapnik V.N., Chervonenkis A.Ya. Theory of pattern recognition. M.: Nauka, 1974. 416 p.
7. Probability and mathematical statistics: encyclopedia / pod red. Yu.V. Prohorova. M.: Bol'shaya rossijskaya enciklopediya, 2003. 910 p.
8. Gogolevskij A.S. Fuzzy Bayesian regression model with dependent variables / LETI // Materialy mezhdunar. konf. po myagkim vychisleniyam i izmereniyam. SPb., 2011. P. 205–208.
9. Gogolevskij A.S. Development of methods and models for classifying various objects of forest systems with a limited training sample / RGGMU // Sbornik tez. shestnadcatoy S.-Peterb. Assamblei molodyh uchenyh i specialistov. SPb., 2011. P. 198–200.
10. Gogolevskij A.S., Ilyushchenko V.V. Analysis of linear classification methods with a limited training sample for forestry tasks // Lesa Rossii v XXI veke: sb. materialov mezhdunar. nauch.-prakticheskoy internet-konf., okt., 2010 g. SPb., 2010. P. 209–211.
11. Gogolevskij A.S., Utkin L.V. The support vector method in the classification of objects of forest systems / VoGTU // Aktual'nye problemy razvitiya lesnogo kompleksa: materialy mezhdunar. nauch.-tekhnicheskoy konf. Vologda, 2011. P. 3–5.
12. Golovko V.A. Neural networks: training, organization and application. M.: IPR-ZHR, 2001. 256 p.
13. Zhuravlev YU.I., Ryazanov V.V., Sen'ko O.V. "Recognition". Mathematical methods. Software system. Practical applications. M.: Fazis, 2006. 159 p.
14. V'yugin V.V. Mathematical foundations of the theory of machine learning and forecasting. M., 2013. 387 p.
15. Latest image processing techniques / pod red. A. A. Potapova. M.: Fizmatlit, 2008. 496 p.
16. Merkov A.B. Introduction to statistical training. M.: Editorial URSS, 2011. 256 p.
17. Afanas'ev A.P., Dzyuba S.M. An elementary introduction to the theory of extremal problems. M.: Izd-vo MFTI, 2008. 186 p.
18. Gogolevskij A.S. Intelligent system for detecting anomalous measurements based on a single-class classification // Sbornik tez. semnadcatoy S.-Peterb. Assamblei molodyh uchenyh i specialistov. SPb., 2012. P. 198–200.
19. Gogolevskij A.S. The data conversion method for detecting abnormal system behavior / LETI // Materialy mezhdunar. konf. po myagkim vychisleniyam i izmereniyam. SPb., 2013. P. 164–166.
20. Physical Encyclopedic Dictionary / gl. red. A.M. Prohorov. M.: Sov. enciklopediya, 1984. 944 p.
21. Schölkopf B., Smola A.J. Learning with Kernels. MIT Press, 2002.
22. Wasserman L. All of Nonparametric Statistics. Springer, New York, 2006.
23. Mullin M., Sukthankar R. Complete Cross-Validation for Nearest Neighbor Classifiers // Proceedings of International Conference on Machine Learning. 2000. P. 1137–1145.
24. Dzhonson H., Lion F. Statistics and planning of an experimenter in technology and science. Data processing methods: pers. angl. M.: Mir, 1980. 611 p.

References

1. Gribanov D.D. General measurement theory: monogr. M.: NIC Infra-M, 2015. 116 p.
2. Mironovskij L.A., Slaev V.A. Algorithms for evaluating the result of three measurements. SPb.: Professional, 2010. 192 p.