

УДК 681.326

Алгоритм обучения модели диагностирования системы холодоснабжения по параметрам рабочих процессов при ограниченной статистической информации

Д-р техн. наук В. О. САЙДАНОВ, канд. техн. наук Ю. Е. ТУПИЦИН,

канд. техн. наук А. С. МАТЮНИН*

Военно-космическая академия имени А. Ф. Можайского

*E-mail: vka@mil.ru

Статья посвящена моделированию отказов систем холодоснабжения на основе статистики о поведении параметров. Раскрываются известные подходы к построению моделей диагностирования сложных систем. Структура модели предполагает декомпозицию системы с учетом особенностей функционирования. Обучение модели построено на основе рекуррентного алгоритма, использующего априорные статистические данные о системе. В результате обучения моделируются эталонные изображения неработоспособных состояний системы. Обучение предлагается производить с использованием тригонометрического базиса. Предложен ортогональный тригонометрический базис с произвольной областью ортогональности — это инновационный подход, который может быть использован для улучшения сходимости процесса обучения моделей диагностирования. Этот метод основан на математическом аппарате функционального анализа и позволяет генерировать данные, которые могут быть использованы для обучения моделей машинного обучения. Приводится пример использования предложенного алгоритма обучения модели диагностирования системы холодоснабжения.

Ключевые слова: диагностические параметры, неработоспособное состояние; ортогональное преобразование, процесс обучения.

Информация о статье:

Поступила в редакцию 17.06.2025, одобрена после рецензирования 10.10.2025, принята к печати 17.10.2025

DOI: 10.17586/1606-4313-2025-24-4-91-98

Язык статьи — русский

Для цитирования:

Сайданов В. О., Тупицин Ю. Е., Матюнин А. С. Алгоритм обучения модели диагностирования системы холодоснабжения по параметрам рабочих процессов при ограниченной статистической информации. // Вестник Международной академии холода. 2025. № 4. С. 91–98. DOI: 10.17586/1606-4313-2025-24-4-91-98

Algorithm for learning a model for diagnosing a refrigeration system based on workflow parameters with limited statistical information

D. Sc. V. O. SAIDANOV, Ph. D. Yu. E. TUPITSIN, Ph. D. A. S. MATYUNIN*

Military Space Academy named after A. F. Mozhaisky

*E-mail: vka@mil.ru

The article concerns the simulation of failures of refrigeration systems based on statistics on the behavior of parameters. The well-known approaches to building models for diagnosing complex systems are revealed. The structure of the model assumes the decomposition of the system, taking into account the specifics of its functioning. The model's training is based on a recurrent algorithm that uses a priori statistical data about the system. As a result of the training, reference images of inoperable states of the system are modeled. The training is proposed to be conducted using a trigonometric basis. An orthogonal trigonometric basis with an arbitrary domain of orthogonality is proposed, which is an innovative approach that can be used to improve the convergence of the learning process of diagnostic models. This method is based on the mathematical apparatus of functional analysis and allows you to generate data that can be used to train machine learning models. An example of using the proposed algorithm for learning a model for diagnosing a refrigeration system is given.

Keywords: diagnostic parameters, inoperable state; orthogonal transformation, learning process.

Article info:

Received 17/06/2025, approved after reviewing 10/10/2025, accepted 17/10/2025

DOI: 10.17586/1606-4313-2025-24-4-91-98

Article in Russian

For citation:

Saidanov V. O., Tupitsin Yu. E., Matyunin A. S. Algorithm for learning a model for diagnosing a refrigeration system based on workflow parameters with limited statistical information. *Journal of International Academy of Refrigeration*. 2025. No 4. p. 91-98. DOI: 10.17586/1606-4313-2025-24-4-91-98

Введение

Техническое диагностирование по параметрам рабочих процессов сложных технических систем и систем холодоснабжения (СХС), в частности, является одним из наиболее эффективных методов оценки состояния оборудования и систем. Этот подход основан на анализе данных, которые непосредственно отражают функционирование системы холодоснабжения в реальных условиях. При этом под отказом понимают выход одного из параметров за допустимые значения [1]–[5].

Таковыми параметрами, определяющими техническое состояние оборудования системы холодоснабжения, могут быть: температура испарения и конденсации хладагента, давление в контурах высокого и низкого давления, перепад давления на фильтрах-осушителях и ряд других.

Функционирование СХС характеризуется динамическими процессами, взаимосвязанными параметрами и эксплуатационными особенностями, на основании которых можно определять эффективность, надежность и другие свойства этих систем. Современное оборудование комплектуется системами индикации и мониторинга, для качественного управления, своевременного технического обслуживания, а также предотвращения выхода из строя оборудования.

Мониторинг количественных показателей динамических процессов можно представить в виде траектории изменения какого-либо параметра. Техническое состояние системы в таком случае представляется в следующем виде:

$$\mathbf{Y}_{(n)} = (y_1, y_2, \dots, y_n)^T. \quad (1)$$

В данном случае координаты y_j , $j = \overline{1, n}$ выражения (1) представляют собой контролируемые параметры, а реализация траекторий вида (1) представляет собой наблюдаемое состояние СХС.

Разработка и обучение модели диагностирования СХС заключается в следующем. Имеется следующая априорная информация:

1. Перечень всех неработоспособных состояний СХС:

$$\tilde{Y} = \{Y^i | i = \overline{1, m}\}. \quad (2)$$

При построении модели под отказом в системе холодоснабжения понимается достижение одним из диагностических параметров предельного допустимого граничного значения, что позволяет более точно описать математическую модель и процедуру синтеза данных. В этом контексте каждое подмножество Y^i неработоспособных состояний представляет собой ограниченную область в евклидовом пространстве

$$\Delta_{ij} = [y_{ij}^H; y_{ij}^B], \quad i = \overline{1, m}, \quad j = \overline{1, n}, \quad (3)$$

где y_{ij}^H – нижнее граничное значение и y_{ij}^B – верхнее граничное значение j -го контролируемого параметра i -го неработоспособного состояния СХС; m — количество неработоспособных состояний, которые могут быть описаны и учтены в модели диагностирования системы.

2. Ограниченная по объему выборка наблюдаемых состояний вида (1), принадлежность каждому неработоспособному состоянию известна и характеризуется множественной определенностью:

$$\begin{aligned} \{Y_k^1 | k = \overline{1, N^1}\} &\subset Y^1; \\ \{Y_k^2 | k = \overline{1, N^2}\} &\subset Y^2; \\ \{Y_k^m | k = \overline{1, N^m}\} &\subset Y^m, \end{aligned} \quad (4)$$

где Y^i , $i = \overline{1, m}$ – подмножество наблюдаемых состояний, N^i — мощность выборки по i -му неработоспособному состоянию.

На основе исходных данных (1) — (4) требуется построить множество изображений

$$E = \{E^i | i = \overline{1, m}\}, \quad (5)$$

где

$$\mathbf{E}^i = (e_{i1}, e_{i2}, \dots, e_{in})^T \quad (6)$$

представляет собой изображение i -го неработоспособного состояния, в виде вектора со свойствами, соответствующими неработоспособному состоянию СХС.

Состояние вопроса

Для возможности применения значений рабочих параметров вида (1) для контроля и диагностирования технического состояния требуется разработка математического обеспечения, поскольку это является необходимым условием определения вида технического состояния и обеспечения требуемой достоверности диагностирования оборудования систем холодоснабжения. Для математического обеспечения необходимо формализованное описание неработоспособных состояний СХС, соответствующих отказам конкретным элементам системы.

Научным фундаментом диагностирования сложных систем на основе формализации процесса отнесения наблюдаемого состояния системы к определенному отказу является теория распознавания образов [1]. Каждое неработоспособное состояние определяется отдельным отказом, его формализованное описание называется изо-

бражением [2]. При этом количество неработоспособных состояний системы определяется вертикальной и горизонтальной декомпозицией системы. Модель диагностирования строится на основе множества изображений и их иерархии.

Теоретическим и практическим вопросам диагностирования по параметрам рабочих процессов в различных областях техники посвящены многочисленные научные исследования [3]–[11]. Часть работ посвящена диагностированию климатического оборудования. Следует отметить, что в рассмотренных научных работах отмечается существенный пробел в исследованиях, связанный с недостаточной проработкой вопросов практического использования накопленных статистических данных о состоянии диагностируемых систем.

Существующие методики преимущественно ориентированы на обработку текущих измерений, не разработаны эффективные механизмы интеграции априорных данных в процесс принятия диагностических решений, отсутствуют универсальные алгоритмы верификации и актуализации априорной информации. Перспективные направления исследований направлены на развитие методов и подходов [12, 13] к обучению моделей диагностирования с использованием априорных данных и распознавания технического состояния СХС.

Материалы и методы исследований

Процесс синтеза изображения системы холодоснабжения на основе обучения

Анализ имеющихся статистических данных по параметрам рабочих процессов СХС показывает, что статистические данные (4) используются фрагментарно, без системного подхода, не учитывается временная динамика изменения параметров системы и априорные данные необходимые для обучения получаются небольшого объема и неоднородными. Неоднородные данные малых объемов получаются вследствие разнородности форматов данных, несбалансированностью классов отказов, различной дисперсией в сформированных подмножествах и ограниченным количеством наблюдений вследствие ограничения по времени при разных режимах. Эффективным методом для решения задач статистического оценивания при ограниченной исходной информации применяемым при построении диагностических моделей является итеративный метод стохастической аппроксимации [14, 15]. Метод стохастической аппроксимации достаточно хорошо разработан и включает многочисленные алгоритмы, но наиболее часто при решении задачи построения изображений применяется вычислительная процедура, которая реализуется на основе следующего рекуррентного соотношения:

$$\mathbf{E}^i(k) = \mathbf{E}^i(k-1) - 1/k [\mathbf{E}^i(k-1) - G(\mathbf{Y}^i(k))], \quad i = \overline{1, m}. \quad (7)$$

Соотношение (7) — это математическое выражение, которое определяет последовательность значений $\mathbf{E}_i(k)$ на основе предыдущих элементов $\mathbf{E}_i(k-1)$, начиная с элементов выражения (4).

Выражение (7) представляет собой векторную функцию:

$$G(\mathbf{Y}^i) = (g_1(\mathbf{Y}^i), g_2(\mathbf{Y}^i), \dots, g_n(\mathbf{Y}^i))^T, \quad (8)$$

которая преобразуется в новую систему координат, где каждая компонента представлена в виде ортогональных функций, а g_n новые координатные функции, выраженные через ортогональный базис:

$$(g_r, g_s) = 0, \quad r = \overline{1, n}, \quad s = \overline{1, n}, \quad r \neq s. \quad (9)$$

Для ортогонального преобразования функции (8) в работах [5, 12, 13] предложено использование тригонометрического базиса:

$$1, \sin lx, \cos lx \quad l \in \mathbf{N}, x \in \mathbf{R}, \quad (10)$$

где $\mathbf{N} = \{1, 2, 3, \dots\}$; $\mathbf{R} = (-\infty, +\infty)$.

Преимущества использования тригонометрического базиса: ортогональность, гибкость и эффективность, которые позволяют разделить данные на независимые компоненты и подходят для анализа периодических и непериодических параметров и упрощают вычисления и улучшает сходимость алгоритмов обучения.

Тригонометрический базис (10) состоит из функций синуса и косинуса, которые являются ортогональными на определенном интервале (обычно $[-\pi, \pi]$) и произведение в линейном пространстве задается следующей математической конструкцией:

$$(g_r, g_s) = \int_{-\pi}^{\pi} g_r g_s dx, \quad r, s \in \mathbf{N}, \quad r \neq s.$$

В рамках данного исследования вместо элементов g_r, g_s используются функции предложенного тригонометрического базиса из (10):

$$\begin{aligned} (\sin rx, \cos sx) &= \int_{-\pi}^{\pi} \sin rx \cdot \cos sx dx = 0; \\ (\sin rx, \sin sx) &= 0; \quad (\cos rx, \cos sx) = 0; \\ (1, \cos sx) &= 0; \quad (1, \sin sx) = 0. \end{aligned}$$

С учетом того, что выражение (10) представляет собой ортогональный базис, а его элементы соответствуют условию попарной ортогональности означает возможность построения системы (8) [12, 13]. Координаты данного выражения определены следующим образом:

$$g_r(\mathbf{Y}) = \begin{cases} \delta_{rj} \sin(l y)_j, & l = (j+1)/2, \quad j - \text{нечетно}; \\ \delta_{rj} \cos(l y)_j, & l = j/2, \quad j - \text{четно}; \\ r, j = \overline{1, n}. \end{cases} \quad (11)$$

где символ Кронекера δ_{rj} — дискретная функция двух целочисленных индексов r и j , определяемая следующим образом:

$$\delta_{rj} = \begin{cases} 1, & r = j \\ 0, & r \neq j \end{cases} \quad \text{— символ Кронекера.} \quad (12)$$

Использование символа Кронекера — это ключевой инструмент формализации условий ортогональности параметров $g_r(\mathbf{Y})$ и увеличения сходимости обучения в задачах построения и обучения диагностических моделей.

Расширение области ортогональности тригонометрического базиса

Ортогональность базиса является ключевым свойством и гарантирует минимальную избыточность представления данных, что критически важно для систем и моделей диагностирования. Для классического тригонометрического базиса [5, 12, 13] является интервал $[-\pi; \pi]$, при котором, получается строгая попарная ортогональность выполняется при условии:

$$|y_j| \leq \pi, \quad j = \overline{1, n}. \quad (13)$$

Если диагностические параметры системы холодо-снабжения выходят за пределы этого интервала (13), ортогональность базиса нарушается. Параметры СХС в реальных условиях эксплуатации могут принимать произвольные конечные значения в пределах физически допустимых диапазонов и часто демонстрируют нелинейные взаимосвязи между различными показателями. При нарушении условия ортогональности усложняется выделение информативных признаков и увеличивается вычислительная сложность задач аппроксимации, требуется большее количество итераций для достижения сходимости, координатные функции становятся зависимыми, что усложняет процесс обучения модели. Снижается точность и достоверность диагностирования.

Следовательно, необходимо найти методы, которые сохраняют ортогональность (8) независимо от диапазона параметров оборудования СХС:

$$|y_j| \leq z, \quad j = \overline{1, n}, \quad z \in \mathbf{R}^+, \quad (14)$$

где $\mathbf{R}^+$ — множество положительных вещественных чисел.

Для переноса тригонометрического базиса на произвольный интервал $[-z; z]$ выполним преобразование аргумента. Гармонический анализ допускает определение ортогональных базисных функций для произвольного интервала:

$$\sin \frac{\pi}{z} lx, \quad \cos \frac{\pi}{z} lx.$$

Получили адаптивный базис с новым с периодом $T = 2\pi/l$ и выбором интервала ортогональности $[-z; z]$:

$$1, \sin \frac{\pi}{z} lx, \cos \frac{\pi}{z} lx. \quad (15)$$

Для доказательства ортогональности системы базисных функций (15) на интервале $[-z; z]$ необходимо показать, что:

$$\begin{aligned} \sin \frac{\pi}{z} rx \cdot \cos \frac{\pi}{z} sx &= \int_{-z}^z \sin \frac{\pi}{z} rx \cdot \cos \frac{\pi}{z} sx dx = \\ &= \frac{1}{2} \left(\int_{-z}^z \sin \frac{\pi}{z} (r+s)x dx + \int_{-z}^z \cos \frac{\pi}{z} (r-s)x dx \right) = \\ &= -\frac{1}{2} \left(\frac{z}{\pi(r+s)} \cos \frac{\pi}{z} (r+s)x \Big|_{-z}^z + \frac{z}{\pi(r-s)} \cos \frac{\pi}{z} (r-s)x \Big|_{-z}^z \right) = \\ &= -\frac{1}{2} \left(\frac{z}{\pi(r+s)} \left(\cos \frac{\pi}{z} (r+s)z - \cos \frac{\pi}{z} (r+s)(-z) \right) + \right. \\ &\quad \left. + \frac{z}{\pi(r-s)} \left(\cos \frac{\pi}{z} (r-s)z - \cos \frac{\pi}{z} (r-s)(-z) \right) \right) = \\ &= -\frac{1}{2} \left(\frac{z}{\pi(r+s)} (\cos(r+s)\pi - \cos(r+s)\pi) + \right. \\ &\quad \left. + \frac{z}{\pi(r-s)} (\cos(r-s)\pi - \cos(r-s)\pi) \right) = 0. \end{aligned}$$

Попарные скалярные произведения остальных элементов базиса равны нулю:

$$\begin{aligned} \sin \frac{\pi}{z} rx \cdot \sin \frac{\pi}{z} sx &= 0; \quad \cos \frac{\pi}{z} rx \cdot \cos \frac{\pi}{z} sx = 0; \\ 1 \cdot \sin \frac{\pi}{z} sx &= 0; \quad 1 \cdot \cos \frac{\pi}{z} sx = 0. \end{aligned}$$

Ширину диапазона ортогональности базиса (15) предлагается выбирать исходя из максимальной координаты по модулю вектора наблюдаемого состояния (1):

$$z = \max \left\{ |y_j| \mid j = \overline{1, n} \right\}. \quad (16)$$

Условие (16) определяет минимальный интервал, покрывающий все координаты наблюдаемого состояния $\mathbf{Y}$. Это важно, потому что работа в более узком интервале исключает избыточные данные, которые могут усложнить вычисления и снизить точность. Выражение (16) задает граничные точки в пространстве $[-z; z]$, поэтому переход к использованию (16) позволяет сохранить ортогональность функций, упрощая вычисления, сохраняя свойства базиса. Получается интервал выбран правильно, базис остается ортогональным, и расчеты становятся эффективнее. Необходимо подчеркнуть преимущество такого подхода в уменьшении вычислений, повышении точности, исключение лишней данных.

Предложенный базис (15) строго ортогонален на любом интервале $[-z; z]$, выражение (11) необходимо задать в конкретном виде:

$$g_r(\mathbf{Y}) = \begin{cases} \delta_{rj} \sin \left(\frac{\pi}{z} ly_j \right), & l = (j+1)/2, \quad j - \text{нечетно}; \\ \delta_{rj} \cos \left(\frac{\pi}{z} ly_j \right), & l = j/2, \quad j - \text{четно}; \\ r, j = \overline{1, n}. \end{cases} \quad (17)$$

Первый шаг алгоритма — инициализация начального приближения для дальнейшего обучения начиная с $\mathbf{Y}^i$ из (4) с учетом (17):

$$\mathbf{E}^i = G(\mathbf{Y}^i), \quad i = \overline{1, m}. \quad (18)$$

На последующих шагах модель уточняет это приближение на основе выражения (7), при помощи которого реализуются второй и последующие шаги преобразования.

Предложенная математическая конструкция, основанная на тригонометрическом преобразовании и формирующая ограниченное евклидово пространство $G(Y)$ в интервале значений $[-1; 1]$. Тригонометрическое преобразование действует как аналог стандартизации, ограничивая динамический диапазон параметров. Ограниченность $G(Y)$ предотвращает искажения параметров при обучении и эти параметры также ограничены полученным интервалом. В результате преобразования получаются области $G(Y)$, полученные области могут пересекаться. Пространство $G(Y)$ охватывает множество (5) построенных изображений модели системы $E \subset G(Y)$.

Теоретическая оценка сходимости процесса обучения модели диагностирования системы холодоснабжения

Учитывая метрические свойства пространства $G(Y)$, сформулируем достаточное условие сходимости процесса обучения модели:

$$\lim_{k \rightarrow \infty} \rho(\mathbf{E}^i(k-1), \mathbf{E}^{i^*}(k)) = 0, \quad (19)$$

где $E^{i*}(k)$ — эталон неработоспособного состояния, соответствующий отказу i -го элемента;

$$\rho(\mathbf{E}^i(k-1), \mathbf{E}^{i*}(k)) = \left(\sum_{j=1}^n (e_j^{i*}(k) - e_j^i(k-1))^2 \right)^{0.5}$$

— евклидово расстояние в пространстве $G(Y)$.

Приближенная оптимальность (19) достигается не асимптотически (при $k \rightarrow \infty$), а на конечном шаге $k = \max$, определяемом объемом выборки N . Условие (19), дающее бесконечный результат, справедливо только в идеализированном случае неограниченных данных и вычислительных ресурсов. В реальности такой сценарий невозможен из-за конечности выборки (4). Результат на шаге $k = \max$ является приближением к истинному распределению данных:

$$\mathbf{E}^{i*}(k) = \mathbf{E}^{i*}(N^i), \quad i = \overline{1, m}. \quad (20)$$

В качестве графической интерпретации процесса обучения модели системы холодоснабжения на рис. 1 представлен график построения оптимального изображения в двумерном пространстве нормированных предложенным способом диагностических параметров e_{i1} и e_{i2} . Для понимания сходимости процесса обучения и достижения результата введен третий показатель L , характеризующий ход обучения. При минимальном его значении можно говорить о максимальной близости к эталонному значению и завершении процесса обучения (19).




Рис. 1. Графическая интерпретация процесса обучения модели

Fig. 1. Graphical interpretation of the model training process

Результаты и обсуждение

Распознавание текущих состояний системы холодоснабжения на основе метрики пространства $G(Y)$

Для измеренных значений параметров рабочих процессов системы холодоснабжения наблюдаемое наблюдаемого состояния $\mathbf{Y}$, отсутствующего в обучающей выборке, применяется метод минимума метрического различия в пространстве $G(\mathbf{Y})$. Текущие значения параметров $\mathbf{Y}$ преобразуются с использованием тригонометрического базиса (17), вычисляется расстояние до эталонных состояний. Преобразованное текущее наблюдаемое состояние $G(\mathbf{Y})$ отождествляется с таким эталонным значением [5, 16], который расположен ближе в пространстве $G(Y)$ из множества (5):

$$Y \in Y^i, \text{ если } \rho(G(Y), E^i) = \min_{k=1, m} \left\{ \rho(G(Y), E^k) \right\}, \quad (21)$$

$$i = \overline{1, m}.$$

Метод минимума метрического различия особенно эффективен для систем с четко выраженными классами состояний. Его ключевое преимущество — прозрачность принимаемых решений, что критически важно для систем холодоснабжения и метод демонстрирует наилучшие результаты при работе с ограниченным и замкнутыми пространствами значений параметров и исключает противоречивые выводы благодаря свойствам ограниченного метрического пространства [16, 17].

Условие (19), определяющее сходимость процесса обучения, допускает вариативность конечных результатов. Систематическое сравнение результатов обучения позволяет выявлять оптимальные конфигурации обучения моделей диагностирования. Пример которых приведен на рис. 1. Показателем будет являться евклидово расстояние ρ — длина каждого шага обучения, как третья координата l фигуры, изображенной на рис. 1:

$$\rho(\mathbf{E}^i(k-1), \mathbf{E}^i(k)) = l. \quad (22)$$

В данном исследовании приводятся два базиса (10) и (15).

На рис. 1 представлено сопоставление двух подходов к обучению модели. Изображенный слева использует базис (10) и характеризуется более протяженной траекторией оптимизации, большей длиной пути сходимости. Процесс обучения изображенный справа основан на применении базиса (15), демонстрирует более эффективную сходимость, устойчивое монотонное уменьшение l . Разница в длинах $l_2 < l_1$ свидетельствует о том, что базис (15) обеспечивает более быструю сходимость. Для сравнения двух процессов обучения предлагается пользоваться следующим выражением:

$$L = \left| \frac{l_1 - l_2}{l_1} \right| \cdot 100. \quad (23)$$

В качестве примера рассмотрим наблюдаемое состояние системы, которое задано вектором, включающим 5 диагностических параметров:

$$\mathbf{Y} = (y_1, y_2, y_3, y_4, y_5)^T.$$

На рис. 2. показан внешний вид воздушно-водяной холодильной машины с непосредственным охлаждением.

Для формирования отказа будем использовать следующие регистрируемые параметры: температуры воды на входе в систему y_1 , температуры воды на выходе из системы y_2 , разности температур на входе и выходе y_3 , значения высокого давления хладагента y_4 , значения низкого давления хладагента y_5 .

Для i -го типа неработоспособного состояния системы была подготовлена репрезентативная обучающая выборка, включающая 12 характерных примеров ($N_i = 12$).

Данная выборка содержит:

$$Y_1^i = (22, 13,8, 5,2, 27,4, 21,7)^T;$$

$$Y_2^i = (4,5, -3,9, 5,4, 27,7, 19,1)^T;$$

$$Y_3^i = (9,8, 0,9, 5,9, 28,6, 19,2)^T;$$

$$Y_4^i = (16,2, 7,6, 5,6, 27,1, 18,9)^T;$$

$$Y_5^i = (11,6, 2,8, 5,8, 26,2, 18,7)^T;$$

$$Y_6^i = (6,9, -2, 5,9, 28,5, 21,6)^T;$$

$$Y_7^i = (17,7, 9, 5,7, 25,2, 18,7)^T;$$

$$Y_8^i = (17,3, 8,4, 5,9, 28,1, 18)^T;$$

$$Y_9^i = (4,4, -4,3, 5,7, 28,3, 18,1)^T;$$

$$Y_{10}^i = (20,9, 12,4, 5,5, 28,3, 18,1)^T;$$

$$Y_{11}^i = (22,1, 13,7, 5,4, 26,3, 20,1)^T;$$

$$Y_{12}^i = (20, 11, 6, 25,6, 19,7)^T.$$

Рассмотрим процесс построения изображения i -го неработоспособного состояния холодильной машины, в общем виде, когда в машине присутствует единичный параметрический отказ.

Фактические значения диагностических параметров выходят за пределы ортогональности базиса (10):

$$\forall Y_k^i \exists y_{kj}^i, j = \overline{1,5}: |y_{kj}^i| > \pi.$$

Руководствуясь положениями, озвученными выше, построение изображения будем проводить на основании (15) или, другими словами, в выражении (7) использовать подход (8) с учетом функций (17). Примем максимальное значение $z(k)$ каждого вектора как величину, ограничивающую область ортогональности базиса (9):

$$z(1) = \max \{22, 13,8, 5,2, 27,4, 21,7\} = 27,4.$$

Первый шаг с учетом (19) и (20) представим следующим образом

$$E^i(1) = G(Y^i(1)) = \begin{pmatrix} \sin(\pi/27,4) \cdot 22 \\ \cos(\pi/27,4) \cdot 13,8 \\ \sin(\pi/27,4) \cdot 5,2 \cdot 2 \\ \cos(\pi/27,4) \cdot 27,4 \cdot 2 \\ \sin(\pi/27,4) \cdot 21,7 \cdot 3 \end{pmatrix} = \begin{pmatrix} 0,58 \\ -0,01 \\ 0,93 \\ 1 \\ 0,92 \end{pmatrix}.$$

Следующее преобразование строим на основе второго элемента выборки:

$$z(2) = \max \{4,5, -3,9, 5,4, 27,7, 19,1\} = 27,7.$$

$$G(Y^i(2)) = \begin{pmatrix} \sin(\pi/27,7) \cdot 22 \\ \cos(\pi/27,7) \cdot 13,8 \\ \sin(\pi/27,7) \cdot 5,2 \cdot 2 \\ \cos(\pi/27,7) \cdot 27,4 \cdot 2 \\ \sin(\pi/27,7) \cdot 21,7 \cdot 3 \end{pmatrix} = \begin{pmatrix} 0,49 \\ -0,9 \\ 0,94 \\ 1 \\ 0,21 \end{pmatrix};$$

из (8) следует:



Рис. 2. Воздушно-водяная холодильная машина

Fig. 2. Air-water refrigerating machine

$$E^i(2) = E^i(1) - \frac{1}{2} [E^i(1) - G(Y^i(2))] = \begin{pmatrix} 0,58 \\ -0,01 \\ 0,93 \\ 1 \\ 0,92 \end{pmatrix} - \frac{1}{2} \begin{pmatrix} 0,58 & 0,49 \\ -0,01 & 0,9 \\ 0,93 & -0,94 \\ 1 & 1 \\ 0,92 & 0,21 \end{pmatrix} = \begin{pmatrix} 0,54 \\ 0,45 \\ 0,94 \\ 1 \\ 0,57 \end{pmatrix}.$$

Все шаги алгоритма реализуются по единой методологии представлены в табл. 1.

Выражение (20) определяет в качестве эталонного изображения $E^i = E^i(12)$.

Критерием сходимости процесса обучения расстояний (22) на предпоследнем и последнем шагах обучения:

$$l_2 = \rho(E^i(11), E^i(12)) = ((0,73-0,72)^2 + (0,59-0,56)^2 + (0,96-0,96)^2 + (1-1)^2 (0,33-0,37)^2)^{0,5} = 0,05.$$

Проведено параллельное обучение диагностической модели с использованием тригонометрического базиса (10) в качестве системы координатных функций на основе этой же обучающей выборки ($N_i = 12$). Рекуррентный алгоритм (7) модифицирован подстановкой функций базиса (11). Полная последовательность этапов детально представлена в исследовании [12], сходимость процесса обучения (22) определяется выражением:

$$l_1 = \rho(E^i(11), E^i(12)) = 0,06.$$

Эффективность предлагаемого подхода определяется (23) относительно l_1 и l_2 :

$$L = \frac{0,06 - 0,05}{0,06} \cdot 100 \approx 17\%.$$

Проведенный эксперимент наглядно демонстрирует ключевое преимущество адаптивного тригонометрического ортогонального базиса в пространстве $[-z; z]$, при равном объеме выборки ($N_i = \text{const}$) достигается более точная аппроксимация оптимального изображения или, другими словами, максимальное сближение полученного изображения с оптимальным.

Таблица 1

Пошаговая реализация обучения модели диагностирования

Table 1

Step-by-step implementation of diagnostic model training

Наблюдаемое состояние	Ортогональное преобразование	Промежуточное изображение	Наблюдаемое состояние	Ортогональное преобразование	Промежуточное изображение	Наблюдаемое состояние	Ортогональное преобразование	Промежуточное изображение	Наблюдаемое состояние	Ортогональное преобразование	Промежуточное изображение
$Y^i(1)$	$G(Y^i(1))$	$E^i(1)$	$Y^i(2)$	$G(Y^i(2))$	$E^i(2)$	$Y^i(3)$	$G(Y^i(3))$	$E^i(3)$	$Y^i(4)$	$G(Y^i(4))$	$E^i(4)$
22	0,58	0,58	4,5	0,49	0,54	9,8	0,88	0,65	16,2	0,95	0,73
13,8	-0,01	-0,01	-3,9	0,9	0,45	0,9	1	0,63	7,6	0,64	0,63
5,2	0,93	0,93	5,4	0,94	0,94	5,9	0,96	0,95	5,6	0,96	0,95
27,4	1	1	27,7	1	1	28,6	1	1	27,1	1	1
21,7	0,92	0,92	19,1	0,21	0,57	19,2	0,04	0,39	18,9	0,29	0,37
$Y^i(5)$	$G(Y^i(5))$	$E^i(5)$	$Y^i(6)$	$G(Y^i(6))$	$E^i(6)$	$Y^i(7)$	$G(Y^i(7))$	$E^i(7)$	$Y^i(8)$	$G(Y^i(8))$	$E^i(8)$
11,6	0,98	0,78	6,9	0,69	0,77	17,7	0,8	0,77	17,3	0,93	0,79
2,8	0,94	0,69	-2	0,98	0,74	9	0,43	0,7	8,4	0,59	0,69
5,8	0,98	0,96	5,9	0,96	0,96	5,7	0,99	0,96	5,9	0,97	0,96
26,2	1	1	28,5	1	1	25,2	1	1	28,1	1	1
18,7	0,43	0,38	21,6	0,76	0,44	18,7	0,65	0,47	18	-0,24	0,38
$Y^i(9)$	$G(Y^i(9))$	$E^i(9)$	$Y^i(10)$	$G(Y^i(10))$	$E^i(10)$	$Y^i(11)$	$G(Y^i(11))$	$E^i(11)$	$Y^i(12)$	$G(Y^i(12))$	$E^i(12)$
4,4	0,47	0,75	20,9	0,75	0,75	22,1	0,48	0,73	20	0,63	0,72
-4,3	0,89	0,71	12,4	0,21	0,66	13,7	-0,07	0,59	11	0,22	0,56
5,7	0,95	0,96	5,5	0,93	0,96	5,4	0,96	0,96	6	1	0,96
28,3	1	1	28,7	1	1	26,3	1	1	25,6	1	1
18,1	-0,25	0,31	19,1	-0,01	0,28	20,1	0,8	0,33	19,7	0,82	0,37

Заключение

Основная идея статьи представляет собой подход к обучению модели системы холодоснабжения на основе метода стохастической аппроксимации. Результатом обучения на основании предложенного подхода получается множество эталонов отказов. В процессе обучения применение тригонометрического ортогонального базиса уменьшает корреляцию между параметрами при об-

учении. Адаптация области определения ортогональности базиса повышает сходимость процесса обучения. Стоит отметить практическую значимость подхода: улучшение сходимости может сократить время обучения модели или повысить точность диагностирования, что важно для реальных систем холодоснабжения, где быстрое и точное обнаружение параметрических отказов критично.

Литература

1. Бишоп М. Распознавание образов и машинное обучение. М.: Диалектика, 2020. 962 с.

2. Mello Rodrigo, Moacir Ponti. Machine Learning: A Practical Approach on the Statistical Learning Theory. Springer, 2018. 373 p. DOI: 10.1007/978-3-319-94989-5

3. Лобан А. В. Информационная технология распределенного диагностирования космических аппаратов. Москва-Берлин: Директ-Медиа, 2015. 146 с.

4. Махутов Н. А., Пермяков В. Н., Ахметханов Р. С. и др. Диагностика и мониторинг состояния сложных технических систем. Тюмень: ТИУ, 2017. 632 с.

5. Сеньченков В. И. Модели, методы и алгоритмы анализа технического состояния. Saarbrücken: LAP LAMBERT Academic Publishing, 2013. 377 с.

6. Chunhui Zhao, Furong Gao. Online fault prognosis with relative deviation analysis and vector autoregressive modeling. // Chemical Engineering Science. 2015. V. 138. P. 531–543. DOI: 10.1016/j.ces. 2015.08.037

7. Lu G., Zhou Y., Lu C., Li X. A novel framework of change-point detection for machine monitoring // Mechanical Systems and

References

1. Bishop M. Pattern recognition and machine learning. Moscow: Dialectics, 2020. 962 p. (in Russian)

2. Mello Rodrigo. Machine learning: a practical approach to the theory of statistical learning. Springer, 2018. 373 p. DOI: 10.1007/978-3-319-94989-5

3. Loban A. V. Information technology of distributed diagnostics of spacecraft. Moscow-Berlin: Direct-Media, 2015. 146 p. (in Russian)

4. Makhutov N. A., Permyakov V. N., Akhmetkhanov R. S. and others. Diagnostics and monitoring of complex technical systems. Tyumen: TIU, 2017. 632 p. (in Russian)

5. Senchenkov V. I. Models, methods and algorithms of technical condition analysis. Saarbrücken: LAP LAMBERT Academic Publishing House, 2013. 377 p. (in Russian)

6. Chunhui Zhao, Furong Gao. Online fault prediction with relative deviation analysis and vector autoregressive modeling. *Chemical Engineering*. 2015. Vol. 138. pp. 531–543. DOI: 10.1016/j.ces. 2015.08.037

7. Lu G., Zhou Yu., Lu S., Li H. New change point detection system for monitoring equipment. *Mechanical systems and signal processing*. 2017. Vol. 83. pp. 533–548. DOI: 10.1016/J. YMSP. 2016.06.030

- Signal Processing. 2017. V. 83. P. 533–548. DOI: 10.1016/J. YMSP. 2016.06.030
8. Будко П. А., Винограденко А. М., Литвинов А. И. Экспериментальные исследования кинетического метода контроля и диагностики технических средств // Мехатроника, автоматизация, управление. 2014. № 9. С. 53–58.
 9. Liu W. Y., Gao Q. W., Ye G., Ma R., Han J. G. A novel wind turbine bearing fault diagnosis method based on Integral Extension LMD // Measurement. 2015. Vol. 74. P. 70–77. DOI: 10.1016/J. MEASUREMENT. 2015.06.005
 10. Skliros C., Esperon M. M., Fakhre A., Jennions I. K. A review of model based and data driven methods targeting hardware systems diagnostics // Diagnostyka. 2019. V. 20 (1). P. 3–21. DOI: 10.29354/diag/99603
 11. Shi P., Liang K., Han D., Zhang Yi. A novel intelligent fault diagnosis method of rotating machinery based on deep learning and PSO-SVM // Journal of Vibroengineering. 2017. V. 19 (8). P. 5932–5946. DOI: 10.21595/jve. 2017.18380
 12. Сеньченков В. И., Матюнин А. С. Повышение сходимости обучающих процедур при разработке моделей диагностирования систем // Приборы и системы. Управление, контроль, диагностика. 2020. № 8. С. 18–26. DOI: 10.25791/pribor. 08.2020.1197
 13. Senchenkov V., Absalyamov D., Avsyukevich D. Diagnostics of life support systems with limited statistical data on failures // E3S Web of Conferences (E3S-2019). Vol. 140. No. 05002. 5 p.
 14. Зорич В. А. Математический анализ. Ч. 2. М.: МЦНМО, 2012. 818 с.
 15. Колмогоров А. Н., Фомин С. В. Элементы теории функций и функционального анализа. М.: ФИЗМАТЛИТ, 2009. 572 с.
 16. Сеньченков В. И., Абсальямов Д. Р., Авсюкевич Д. А. Задание множества диагностических параметров системы на основе теории функциональных пространств // Труды СПИИ-РАН. 2019. Т. 18 (4). С. 949–975. <https://doi.org/10.15622/sp. 2019.18.4.949–975>
 17. Muscat Jo. Functional Analysis: An Introduction to Metric Spaces, Hilbert Spaces, and Banach Algebras. Springer, 2014. 420 p. DOI: 10.1007/978-3-319-06728-5
 8. Budko P. A., Vinogradenko A. M., Litvinov A. I. Experimental studies of the kinetic method of control and diagnostics of technical means. *Mechatronics, automation, control*. 2014. No. 9. pp. 53–58. (in Russian)
 9. Liu U. Yu., Gao K. U., Ye G., Ma R., Han J. G. A new method for diagnosing wind turbine bearing malfunctions based on the integrated LMD expansion. *Measurement*. 2015. Vol. 74. pp. 70–77. DOI: 10.1016/J. MEASUREMENT. 2015.06.005
 10. Skliros S., Esperon M. M., Fahre A., Jennions I. K. An overview of diagnostic methods for hardware systems based on models and managed by data. *Diagnostics*. 2019. Vol. 20 (1). pp. 3–21. DOI: 10.29354/diag/99603
 11. Shi P., Liang K., Han D., Zhang I. A new intelligent method for troubleshooting rotating mechanisms based on deep learning and PSO-SVM. *Journal of Vibration Engineering*. 2017. Vol. 19 (8). pp. 5932–5946. DOI: 10.21595/jve. 2017.18380
 12. Senchenkov V. I., Matyunin A. S. Increasing the convergence of training procedures in the development of diagnostic models of systems. *Devices and systems. Management, monitoring, diagnostics*. 2020. No. 8. pp. 18–26. DOI: 10.25791/pribor. 08.2020.1197 (in Russian)
 13. Senchenkov V., Absalyamov D., Avsyukevich D. Diagnostics of life support systems with limited statistical data on failures. *E3S Web conferences* (E3S-2019). Vol. 140. No. 05002. 5 p.
 14. Zorich V. A. Mathematical analysis. Part 2. Moscow: ICNMO, 2012. 818 p. (in Russian)
 15. Kolmogorov A. N., Fomin S. V. Elements of the theory of functions and functional analysis. Moscow: FIZMATLIT, 2009. 572 p. (in Russian)
 16. Senchenkov V. I., Absalyamov D. R., Avsyukevich D. A. Setting a set of diagnostic parameters of a system based on the theory of functional spaces. *Proceedings of SPIIRAN*. 2019. Vol. 18 (4). pp. 949–975. <https://doi.org/10.15622/sp. 2019.18.4.949–975> (in Russian)
 17. Muscat Jo. Functional analysis: an introduction to metric spaces, Hilbert spaces and Banach algebras. Springer, 2014. 420 p. DOI: 10.1007/978-3-319-06728-5

Сведения об авторах

Сайданов Виктор Олегович

Д. т. н., профессор, профессор кафедры систем жизнеобеспечения объектов наземной космической инфраструктуры Военно-космической академии имени А. Ф. Можайского, 197198, Санкт-Петербург, ул. Ждановская, 13.

Тупицин Юрий Евгеньевич

К. т. н., доцент, доцент кафедры систем жизнеобеспечения объектов наземной космической инфраструктуры Военно-космической академии имени А. Ф. Можайского, 197198, Санкт-Петербург, ул. Ждановская, 13.

Матюнин Александр Сергеевич

К. т. н., преподаватель кафедры систем жизнеобеспечения объектов наземной космической инфраструктуры Военно-космической академии имени А. Ф. Можайского, 197198, Санкт-Петербург, ул. Ждановская, 13, vka@mail.ru

Information about authors

Saidanov Viktor O.

D. Sc., Professor, Professor of the Department of Life Support Systems for Ground-based Space Infrastructure Facilities at the Military Space Academy named after A. F. Mozhaitsky, 13 Zhdanovskaya Street, St. Petersburg, 197198.

Tupitsin Yuri E.

Ph. D., Associate Professor, Associate Professor of the Department of Life Support Systems for Ground-based Space Infrastructure Facilities at the Military Space Academy named after A. F. Mozhaitsky, 13 Zhdanovskaya Street, St. Petersburg, 197198.

Matyunin Alexander S.

Ph. D., Lecturer of the Department of Life Support Systems for Ground-based Space Infrastructure Facilities at the Military Space Academy named after A. F. Mozhaitsky, 13 Zhdanovskaya Street, St. Petersburg, 197198, vka@mail.ru



Статья доступна по лицензии
Creative Commons «Attribution-NonCommercial»