

МЕТОДЫ МОНИТОРИНГА ТЕХНИЧЕСКОГО СОСТОЯНИЯ СИСТЕМ В ЦЕЛЯХ УПРАВЛЕНИЯ ИХ ИЗБЫТОЧНОСТЬЮ.

Ч. 3. Неклассические модели в технической диагностике

В. Н. Буков*, А. М. Бронников**, А. С. Попов***, В. А. Шурман****

*АО «Бортовые аэронавигационные системы», г. Москва,

**Московский государственный технический университет им. Н. Э. Баумана,

***ВУНЦ ВВС «Военно-воздушная академия им. проф. Н. Е. Жуковского и Ю. А. Гагарина», г. Воронеж,

****АО «НИИ авиационного оборудования», г. Жуковский, Московская обл.

*✉ v_bukov@mail.ru, **✉ bronnikov_a_m@mail.ru, ***✉ saga30@yandex.ru, ****✉ shurman@niiao.ru

Аннотация. Управление избыточностью технической системы предполагает использование процедуры мониторинга для реконфигурирования системы по мере необходимости. В обзоре, состоящем из четырех частей, приводятся современные методы диагностирования текущего состояния динамических систем как неотъемлемой функции мониторинга. В третьей части обзора изложены методы диагностирования, использующие нейронные сети, нечеткие модели, структурные модели и модели в виде множеств, а также статистический подход. Приводятся основы создания и обучения нейросети с ориентацией на выполнение функции диагностирования. Изложен подход с нечеткими моделями, общие правила формирования моделей и особенности их использования в задаче диагностирования. Продемонстрирован подход со структурными моделями и описаны особенности обнаружения отказов на его основе. Представлены основы методов с использованием аппарата теории множеств, в частности формализма зонотопов. Кратко изложен подход на основе статистического распознавания образов.

Ключевые слова: искусственный нейрон, нейронная сеть, нечеткие модели, функция принадлежности, нечеткая кластеризация, структурные модели, декомпозиция Дулмаджа – Мендельсона, диагностируемость, зонотопы, градации в дискретном пространстве признаков, эмпирическая оценка отношения правдоподобия.

ВВЕДЕНИЕ

Основным ограничением подходов с аналитическими моделями является необходимость точного знания этих моделей (как их структуры, так и параметров), что в практических применениях зачастую неосуществимо. В случае неполной определенности математических моделей есть отработанные процедуры их параметрической или структурной идентификации [1–3]. Однако здесь внимание сосредоточено на «изначальном» (т. е. присутствующем самому подходу) преодолении указанного недостатка. К таким подходам относится исполь-

зование нейронных сетей, нечетких моделей, структурных моделей, аппарата теории множеств, а также статистических оценок.

Сторонники таких методов намеренно или в силу недостаточности информации отказываются от детального описания протекающих в диагностируемой системе процессов. Это так или иначе делает используемые модели грубыми (неточными, приближенными), однако позволяет придать диагностированию большую гибкость, снижающую или полностью обходящую негативные эффекты, чем и мотивировано применение этих подходов для эффективного контроля работоспособности динамических систем [4].

1. НЕЙРОСЕТЕВЫЕ МЕТОДЫ ДИАГНОСТИРОВАНИЯ

Нейронные сети (НС) получили широкое распространение в задачах технической диагностики [5–9]. Вариант таких сетей [10, 11] использует модели нелинейной авторегрессии с экзогенными входами (англ. *Nonlinear AutoRegressive with exogenous inputs*, NARX) в сочетании с алгоритмами обучения.

1.1. Формирование нейросети типа ARX

Один из подходов заключается в разработке и обучении набора нейросетевых оценщиков для воспроизведения поведения исследуемой системы. В структуре i -го отдельного нейрона [12] используется MISO-система (англ. *Multiple Input Single Output* – много входов, один выход), в которой выходной сигнал y_i вычисляется как функция взвешенной суммы всех входов u_i нейрона $u_{i,1}, \dots, u_{i,n_i}$ с соответствующими весами $w_{i,1}, \dots, w_{i,n_i}$, как показано на рис. 1. Функция f называется функцией активации.




Рис. 1. Пример искусственного нейрона

Нейросети классифицируются по способам соединения элементов друг с другом [13, 14]. В сети с прямой связью элементы сгруппированы в однонаправленные слои. Первый из них, а именно входной слой, получает информацию непосредственно с сетевых входов, затем каждый последующий скрытый слой принимает входные данные от нейронов предыдущего слоя и передает выходные данные нейронам следующего слоя, вплоть до последнего выходного слоя, на котором генерируются окончательные сетевые выходные данные. Следовательно, нейроны подключаются от одного

слоя к другому, но не внутри одного и того же слоя. Единственным ограничением является количество нейронов в выходном слое, которое должно быть равно количеству фактических каналов выходных данных сети.

С другой стороны, рекуррентные сети [13] представляют собой многослойные сети, в которых выходные данные некоторых нейронов передаются обратно нейронам, принадлежащим предыдущим слоям, таким образом, информация передается как вперед, так и назад и обеспечивает динамическую память внутри сети.

Промежуточным решением является НС с подключенной линией задержки. Сети такого типа подходят для моделирования или прогнозирования эволюции динамической системы. В частности, разомкнутая сеть NARX при надлежащем обучении может оценить текущие (или последующие) результаты на основе полученных прошлых измерений входных и выходных данных системы.

Вообще говоря, для MIMO-систем (англ. *Multiple Input Multiple Output* – много входов, много выходов) сети NARX с открытым контуром следуют закону

$$\hat{y}_t = f_{\text{net}}(u_t, \dots, u_{t-d_u}, y_{t-1}, \dots, y_{t-d_y}), \quad (1)$$

где $\hat{y}_t$ – оценка выходных данных системы на шаге t ; u и y – измеренные системные входы и выходы; d_u и d_y – количество задержек входов и выходов соответственно; f_{net} – функция, реализуемая сетью и зависящая от архитектуры слоев, количества нейронов, их весов и функций активации. Структура открытой сети NARX (с разомкнутым контуром), используемой в качестве оценщика, показана на рис. 2.




Рис. 2. Открытая динамическая нейросеть

Разница измеренного значения выхода y_t и его оценки (1) принимается в качестве невязки диагностирования r_t .

Когда доступны только входные измерения, сеть NARX может стать динамической НС при замыкании обратной связи сетевых выходов на входы, как показано на рис. 3.




Рис. 3. Замкнутая динамическая нейросеть

Разработчик системы диагностирования может варьировать количество нейронов и связей между ними, в то время как значение весов $w_{i,j}$ внутри каждого нейрона получается путем обучения сети.

Поскольку компоненты НС зачастую выбираются субъективно, они могут быть не вполне адекватны моделируемой системе или процессу, что отражается и на реализациях сетей.

1.2. Обучение нейросети

Нейросеть становится инструментом диагностирования в результате ее обучения (подбора значений весовых коэффициентов w) на предварительно отобранных примерах функционирования диагностируемой системы как в работоспособном состоянии, так и с потерей работоспособности в результате, в частности, возникновения отдельной неисправности или их комбинации. Помимо основного варианта с фиксированными после обучения весовыми коэффициентами возможны варианты с уточнением (дообучением) параметров сети в процессе ее работы. Кроме того, нейросеть всякий раз следует переучивать даже для однотипных объектов, функционирующих в различных условиях и с различными историческими данными об эксплуатации.

Нейросеть можно обучить только тем «диагностическим событиям» (исправным, работоспособным, предотказным и неработоспособным состояниям), которые изначально известны и использованы в процессе обучения. Если не указать нейросети множество допустимых состояний, включая неисправные, то она не различит их, не сможет найти непредусмотренное состояние.

Использование нейронных сетей позволяет на практике решать задачу самодиагностирования, поскольку нейросеть устойчива к аномалиям в данных при правильном обучении и сама распознает диагностическое событие даже при неточности в исходных данных¹. Этого не произойдет в случае применения «жестких» алгоритмов диагностирования.

Формальной целью обучения является минимизация функции потерь (невязки) E [14], зависящей от вектора весовых коэффициентов w , и она может быть реализована в двух различных режимах:

- инкрементный режим (каждая пара вход – цель независимо генерирует обновление весовых коэффициентов сети);
- пакетный режим (все входные данные и функция потерь применяются к сети одновременно).

Хотя второй режим обучения, по сравнению с инкрементным, требует большего объема памяти, он характеризуется более быстрой сходимостью и приводит к меньшим ошибкам.

При наличии шаблонов в количестве S , соответствующих как отсутствию, так и наличию различных неисправностей в системе, для каждой из $P = C_p^2 = S! / 2(S-2)!$ возможных пар вход – выход можно записать вектор ошибок

$$e_p = y_p - \hat{y}_p = [e_{p,1} \quad \dots \quad e_{p,M}]^T, \quad p = \overline{1, P}, \quad (2)$$

где M – число выходов, т. е. искомым невязок диагностируемой системы. Общая же функция потерь, зависящая в соответствии с формулой (1) и рис. 1 от выбора весов $w = (w_1, \dots, w_N)$, принимает вид:

$$E(w) = \frac{1}{2} \sum_{p=1}^P \sum_{m=1}^M (y_{p,m} - \hat{y}_{p,m}(w))^2 = \frac{1}{2} \sum_{p=1}^P \sum_{m=1}^M e_{p,m}^2(w).$$

Любой стандартный алгоритм численной оптимизации [14–16] может быть использован для обновления значений параметров w_i с целью минимизации невязки $E(w)$. Среди них наиболее рас-

¹ Это тезис одного из рецензентов статьи. Авторы приняли с благодарностью.

пространены итеративные, использующие такие характеристики, как:

– градиент функции потерь

$$\text{grad}E = \frac{\partial E}{\partial w} = \left[\frac{\partial E}{\partial w_1} \quad \dots \quad \frac{\partial E}{\partial w_N} \right]^T,$$

– гессиан функции потерь

$$H(E) = \begin{bmatrix} \partial^2 E / \partial w_1^2 & \dots & \partial^2 E / \partial w_1 \partial w_N \\ \vdots & \ddots & \vdots \\ \partial^2 E / \partial w_N \partial w_1 & \dots & \partial^2 E / \partial w_N^2 \end{bmatrix},$$

– якобиан ошибок оценивания

$$J(e) = \begin{bmatrix} \partial e_{1,1} / \partial w_1 & \dots & \partial e_{1,1} / \partial w_N \\ \partial e_{1,2} / \partial w_1 & \dots & \partial e_{1,2} / \partial w_N \\ \vdots & \ddots & \vdots \\ \partial e_{p,M} / \partial w_1 & \dots & \partial e_{p,M} / \partial w_N \end{bmatrix}.$$

Последовательные итерации этих алгоритмов состоят из обновления значений параметров и вычисления нового значения функции потерь до тех пор, пока не будет выполнено условие останова.

Достижимая чувствительность диагностирования к отдельным отказам является сложным вопросом, вряд ли имеющим обобщенную оценку.

В качестве итога отметим, что нейросети аппроксимируют любую нелинейную и динамическую функцию при наличии подходящей структуры весовых коэффициентов. Более того, онлайн-обучение позволяет легко изменять систему диагностирования в тех случаях, когда вносятся изменения в физический процесс или в систему управления. Нейросети могут выполнять функцию обобщения, когда представлены входные данные, отсутствующие в обучающих данных, и принимать разумные решения в случаях зашумленных или поврежденных данных. Они также легко применимы к многопараметрическим системам и имеют высокий уровень параллельности структуры. Нейросеть может одновременно работать с качественными и количественными данными. Кроме того, нейросеть может быть очень полезна, когда отсутствует математическая модель системы, т. е. аналитические модели по какой-либо причине не могут быть применены. Все это вместе, как ожидается, может обеспечить более высокую степень отказоустойчивости.

С другой стороны, принципиальной особенностью нейросети является то, что она работает как «черный ящик», в котором отсутствует качественная и количественная информация о представляемой ею модели. Ввиду этого обстоятельства разработчики и заказчики пока воздерживаются от применения соответствующих решений, прежде всего для задач высокой ответственности (например, в гражданской авиации – для задач, связанных с без-

опасностью). Признано, что существует двусмысленность в отношении работы нейросети в случае непредвиденных ситуаций [17].

Описанный подход таит в себе проблему структурного характера. Заранее практически невозможно подобрать такое сочетание измеряемых параметров и структуры сети, чтобы гарантированно получать уверенное различение отказов из заданного перечня. Обычно это достигается путем проб и ошибок. Кроме того, совокупность обучающих примеров должна быть представительной, т. е. содержать достаточное количество комбинаций условий решаемой задачи.

2. ДИАГНОСТИРОВАНИЕ С НЕЧЕТКИМИ МОДЕЛЯМИ

Подход с нечеткими моделями также помогает обойти проблему точного знания модели диагностируемой системы. При этом такой подход может применяться на двух уровнях: сначала нечеткие описания используются для генерирования невязок, а затем снова с помощью нечеткой логики достигается обнаружение отказов [18–24].

Системы нечеткой логики предлагают лингвистическую модель динамики системы, которую можно легко понять с помощью определенных правил. Им также присущи способности работать с неточными или зашумленными данными.

2.1. Формирование нечеткой модели

Эффективный подход к проектированию системы нечеткой логики начинается с разбиения доступных данных на подмножества (кластеры) [19], характеризующиеся более простым (линейным или аффинным) поведением. Кластер можно определить как группу данных, которые больше похожи друг на друга, чем на данные другого кластера. Сходство между данными обычно выражается в терминах их удаленности от определенного элемента, располагаемого внутри кластера и используемого в качестве прототипа этого кластера. Нечеткая кластеризация обеспечивает эффективный инструмент для разделения данных, при котором переходы между подмножествами являются плавными, определяемыми так называемыми функциями принадлежности, а не резкими.

В общем случае аппроксимация нелинейных MISO-систем может быть достигнута с помощью нечеткого рассуждения [25, 26]. Однако согласно подходу, предложенному в работе [27], следствия становятся четкими функциями входных данных, и каждое нечеткое правило принимает форму

$$R_i : \text{IF } x \in X_i \text{ THEN } \hat{y}_i = a_i^T x + b_i, \quad i = \overline{1, n_c}, \quad (3)$$

где R_i – i -е правило; X_i – i -й кластер; n_c – общее количество кластеров; a_i – вектор параметров; b_i – скалярное смещение; $\hat{y}_i$ – вывод i -го правила, в то время как y_i – выход диагностируемой системы. Правило (3) для одномерной переменной x при $n_c = 5$ иллюстрирует рис. 4.




Рис. 4. Графическая иллюстрация правила (3)

Введение функции принадлежности $\lambda_i(x)$, учитывающей логику выбора кластеров (IF ... THEN ...), позволяет записать результирующую формулу для всего множества правил (3) в виде взвешенной суммы

$$\hat{y}_t = \frac{\sum_{i=1}^{n_c} \lambda_i(x_t) y_t^i}{\sum_{i=1}^{n_c} \lambda_i(x_t)}, \quad (4)$$

где x_t – подходящая комбинация входного и выходного сигналов; y_t^i – выходной сигнал локальной линейной (или аффинной) i -й модели, заданный следующим образом:

$$y_t^i = \sum_{k=1}^n a_{i,k} y_{t-k} + \sum_{k=0}^{n-1} b_{i,k} u_{t-k} + c_i, \quad (5)$$

где $a_{i,k}$, $b_{i,k}$ и c_i – параметры i -й модели в подпространстве (кластере) X_i .

Формула (5) содержит как последние полученные u_t , y_{t-1} , так и предыдущие u_{t-1} , y_{t-2} , ... выборки входных и выходных данных, что отражает динамическое поведение системы. Это соответствует рассмотрению наблюдения как линейной авторегрессионной модели с экзогенными входными данными ARX [9] порядка s , в которой вектор регрессора принимает вид

$$x_t = \left[\underbrace{y_{t-1} \cdots y_{t-s}}_{\text{выходная выборка}} \underbrace{u_t \cdots u_{t-s+1}}_{\text{входная выборка}} \right]^T,$$

где t – текущий момент дискретного времени.

Нечеткая кластеризация [20, 28, 29], в отличие от классической кластеризации, позволяет любому элементу принадлежать нескольким кластерам одновременно.

В качестве иного подхода нечеткой модели можно указать на модель нечеткого конечного автомата², которая используется для описания дискретно-событийных систем [22].

2.2. Диагностирование

В качестве невязки может быть принята разность фактически измеренных и получаемых посредством неявной модели (2) оценок выходов системы:

$$r_t = y_t - \hat{y}_t.$$

Укрупненная схема формирования невязки на основе адаптивной нечеткой модели показана на рис. 5. Нечеткий прототип и рекурсивный вычислитель параметров, реализующий какой-либо алгоритм идентификации, используют независимо одни и те же входные и выходные данные.

При необходимости обнаружения нескольких различных неисправностей схема их определения приводится к виду с мультиплицированием прототипов (моделей). Такая схема будет рассмотрена в ч. 4 обзора.




Рис. 5. Схема вычисления невязки на основе нечеткой модели

Отдельной, но весьма важной проблемой является нечеткая кластеризация пространства состояний системы [31]. Большинство алгоритмов нечеткой кластеризации основаны на оптимизации целевой функции $J(Z, U, V)$ s -средних, выполняемой следующим образом:

² При изложении далее этого подхода авторы отошли от принятой в ч. 2 обзора установки рассматривать только динамические системы с моделями (2) и (3) [30], исходя из того, что описываемый способ формирования симптомов применим и к указанным системам.

- представление данных в матричной форме

$$Z = \begin{bmatrix} z_{11} & \cdots & z_{1N} \\ \vdots & \ddots & \vdots \\ z_{n1} & \cdots & z_{nN} \end{bmatrix},$$

где n – размерность данных (число измерений, выполняемых за одно наблюдение), N – количество доступных наблюдений;

- определение матрицы нечетких разбиений $U = [\mu_{ik}]$, содержащей значения функции принадлежности, где i – номер измерения, k – номер кластера;

- определение центров так называемых прототипов $V = [v_1 \cdots v_{n_c}]$, т. е. точек, по расстоянию до которых оценивается удаленность кластера от текущего состояния системы.

Формула минимизации широко распространенной целевой функции c -средних, сформулированная автором монографии [32], выглядит следующим образом:

$$\begin{aligned} v_k &= \arg \min J(Z, U, V) = \\ &= \arg \min \sum_{k=1}^{n_c} \sum_{i=1}^N (\mu_{ik})^m (z_i - v_k)^T A (z_i - v_k) \end{aligned}$$

с весовым показателем $m > 1$, где матрица A определяет форму кластера.

Для диагностирования отказов на фоне помех измерителей и неопределенностей моделирования требуется соблюдение принципа разделения помех, при котором на генератор невязок не влияют неопределенность моделирования и входные эффекты. Это может быть достигнуто с помощью обобщенных схем наблюдения, условий согласованности [33] или конкретных подходов к проектированию [34].

В статье [22] для дискретно-событийных систем, ведущих себя, как правило, случайным образом [35, 36] и описываемых моделью нечеткого конечного автомата, предлагается метод функционального диагностирования на основе использования математического аппарата нечеткой логики. Ключевым звеном в работе [22] является использование детерминизатора нечеткого конечного автомата, т. е. конечного автомата, одновременно описывающего как исправное, так и неисправное поведение исходного автомата.

По сравнению с алгебраическими подходами [37, 38] к детерминизации нечетких конечных автоматов, сохраняющими размерность исходных автоматов, рассматриваемый подход позволяет использовать при диагностировании дополнительную полезную информацию о степени уверенности

в осуществлении каждого из возможных переходов, что предоставляет потенциальную возможность для увеличения (при необходимости) глубины поиска неисправностей. Плата за это – значительная размерность таблицы переходов детерминизатора.

Схема диагностирования в статье [22] содержит ряд каналов (на единицу больше числа возможных неисправностей в системе). Каждый канал включает наблюдатель в виде детерминизатора нечеткого конечного автомата. Блок принятия решения на основе сравнения выходов дискретно-событийной системы и наблюдателей генерирует решение об исправности или неисправности системы.

Отличительной особенностью метода является то, что для его реализации не требуется предварительное формирование табличного описания средств диагностирования; все вычисления осуществляются непосредственно в процессе диагностирования с использованием компактных аналитических соотношений, что весьма важно для осуществления мониторинга.

В работе [39] представлено исследование по использованию нечеткой логики для диагностирования специфической системы с тремя резервуарами. Необходимо отметить, что этому объекту как тестовому посвящено множество публикаций, где рассматривались различные наблюдатели [40–42] (см. ч. 2 обзора [30]), уравнения паритетности с нейронечеткой идентификацией [43], невязки из физических нелинейных уравнений [44] (как в ч. 2 обзора [30], но уравнения нелинейные), оценка физических параметров с использованием нечетких нейронных сетей [45] и нечеткая модель, основанная на В-сплайне³ сети [46].

Автор работы [39] определяет систему локализации⁴ неисправностей (англ. *Fault Isolation System, FIS*) как четверку

$$FIS = \langle F, S, V, \phi \rangle,$$

где F – множество неисправностей; S – множество симптомов с двухуровневой $\{0, 1\}$ или трехуровневой $\{-1, 0, +1\}$ шкалой; V – множество значений симптомов из интервала $[0, 1]$ или $[-1 \dots +1]$ соответственно; ϕ – функция, определяемая как декартово произведение множеств F и S , т. е. множество всех пар (f_i, s_j) . Особенности вычисления значения симптома иллюстрирует

³ Сокращение от «базисный сплайн», т. е. сплайн с наименьшим носителем для задания степени.

⁴ Под локализацией здесь и далее подразумевается определение места отказа, возникновения неисправного состояния.

рис. 6, где r_j – невязка; $s_j \in S$ – симптом; $v_{ij} \in V$ – непрерывное значение j -го симптома для i -й неисправности; P – позитивная и N –, $N+$ – негативные области оценки симптома.




Рис. 6. Трехуровневая оценка симптома

Диагностирование выполняется по набору сформированных таким образом симптомов с использованием пороговых элементов и правил типа (3) для каждой неисправности. Например, для трехзначных симптомов правила по числу неисправностей имеют вид:

$$R_i : \text{IF } s_1 = 0, s_2 = +1 \text{ or } -1, \\ s_3 = +1 \text{ or } -1, \dots \text{ THEN fault } f_i.$$

В итоге FIS представляет собой таблицу, которая присваивает значение или подмножество значений симптомов s_j каждой неисправности f_i .

Для локализации неисправностей дополнительно вычисляются непрерывные значения симптомов v_{ij} по формулам, аналогичным (4), что позволяет учитывать значимость (степень принадлежности) симптомов.

Выполняемая таким образом интерпретация невязок позволяет учесть основную неопределенность, возникающую в процессе диагностирования, т. е. неопределенность симптомов s_j . Утверждается [40], что такой метод обеспечивает гораздо лучшую устойчивость сгенерированных диагнозов к шумам измерений по сравнению с алгоритмами, использующими проверку порогового значения невязки и логический вывод.

3. СТРУКТУРНЫЕ МЕТОДЫ ДИАГНОСТИРОВАНИЯ

Структурный анализ использует структурное представление модели, которое является грубым описанием, учитывающим только то, какие переменные входят в каждое уравнение, что позволяет эффективно и без численных трудностей анализи-

ровать задачи большой размерности. Однако ценой этого является то, что результаты являются слишком общими. Подход к диагностированию на основе структурного анализа был предложен в многочисленных работах [47–50].

Структурный анализ хорошо поддается компьютерной поддержке, доступной как в среде MATLAB, так и на языке Python.

Графо-теоретический алгоритм, называемый декомпозицией Дулмаджа – Мендельсона, является основополагающим для анализа диагностических свойств моделей [47, 49] и заключается в перестановке строк и столбцов так называемой структурной матрицы системы, содержащей специальные символы, отражающие вхождение переменных в различные уравнения математической модели этой системы.

3.1. Структурные модели

Пусть E – множество ограничений или уравнений в модели, а V – множество переменных, тогда структурная модель может быть представлена двудольным графом $G = (E \cup V, A)$, где A – множество ребер между узлами в двух множествах узлов E и V . Ребро $(e_i, v_j) \in A$ тогда и только тогда, когда переменная $v_j \in V$ встречается в модельном отношении $e_i \in E$. Распространенным способом визуализации структурной модели является так называемая матрица биадьюнктности графа, т. е. матрица, имеющая строки и столбцы, соответствующие ограничениям и переменным. Элемент в позиции (i, j) матрицы биадьюнктности пуст, если переменная v_j не входит в ограничение (уравнение) e_i . Матрица биадьюнктности, представляющая структуру модели, также называется просто структурной матрицей.

Набор переменных V может быть классифицирован как неизвестные $X \subset V$, известные $Z \subset V$ или ошибочные $F \subset V$ при выполнении условия $V = X \cup Z \cup F$. Для целей анализа наиболее важной будет часть структуры, связанная с неизвестными переменными, а подграф, включающий только ограничения (уравнения) и неизвестные переменные, называется сокращенным структурным графом.

Для пояснения и иллюстрации структурного анализа обычно применяется демонстрационный пример. В качестве такового далее используется заимствованная из монографии [49] математическая модель электродвигателя. Уравнения этой модели имеют вид:

$$\begin{aligned}
 e_1: U &= h(R + f_R) + Lh' + K_a h\omega, \\
 e_2: h &= \sqrt{\frac{T_m}{K_a \omega}}, \\
 e_3: J\omega' &= T - b\omega, \\
 e_4: T &= T_m - T_l - f_{\text{load}}, \\
 e_5: y_h &= h + f_h, \\
 e_6: y_\omega &= \omega + f_\omega, \\
 e_7: y_T &= T + f_T, \\
 e_8: \frac{dh}{dt} &= h', \\
 e_9: \frac{d\omega}{dt} &= \omega',
 \end{aligned} \tag{6}$$

где использованы обозначения: U – напряжение питания; T_m – вращающий момент; T_l – момент расчетной нагрузки; h – ток обмотки двигателя; ω – угловая скорость вращения двигателя; R – номинальное сопротивление обмотки двигателя; L – индуктивность обмотки двигателя; K_a – коэффициент электромеханической связи; J – суммарная инерция вращения ротора и нагрузки; b – коэффициент трения.

Двигатель оборудован датчиками, измеряющими силу тока y_h , момент на валу y_T и угловую скорость y_ω . В качестве неисправностей рассматриваются неисправности всех датчиков f_h , f_ω и f_T , неисправность сопротивления обмотки f_R и неучтенная дополнительная нагрузка f_{load} на двигатель.

В данном случае и с учетом введения обобщенных обозначений наборы переменных V включают:

$$X = \{h, h', \omega, \omega', T, T_m, T_l\} = \{x_i\}_{i=1,7},$$

$$Z = \{y_h, y_\omega, y_T, y_U\} = \{y_j\}_{j=1,4},$$

$$F = \{f_R, f_h, f_\omega, f_T, f_{\text{load}}\} = \{f_k\}_{k=1,5}.$$

Кроме того, известны значения таких параметров: R, L, K_a, b, J .

Структурная матрица представляется в виде таблицы (e_i – i -я строка, v_j – j -й столбец, здесь $v_j = \{x_{k=1,7}, y_{l=1,4}, f_{m=1,5}\}$), ячейки которой заполняются следующими знаками: • – если переменная v_j входит в e_i непосредственно; D – если переменная v_j представлена ее производной; I – если переменная v_j представлена ее интегралом.

На рис. 7 представлена исходная структурная матрица, соответствующая модели (6).

Результат декомпозиции Дулмаджа – Мендельсона показан на рис. 8, где путем перестановки ограничений (уравнений) $e_1, \dots, e_5$ и переменных $x_1, \dots, x_4$ матрица биадьюнктности редуцированного структурного графа преобразована к блочной треугольной форме. На диагонали выделены три блока: первые два представляют собой точно определенную M^0 часть (число «внутренних» переменных равно числу уравнений), а третий – переопределенную M^+ часть (число «внутренних» переменных меньше числа уравнений) модели системы.

e_1	•	•	•					•								•
e_2	•					•										
e_3			•	•	•											
e_4					•	•	•					•				
e_5	•							•					•			
e_6			•						•					•		
e_7					•					•					•	
e_8	I	D														
e_9			I	D												
	x_1	x_2	x_3	x_4	x_5	x_6	x_7	f_1	f_2	f_3	f_4	f_5	y_1	y_2	y_3	y_4

Рис. 7. Структурная матрица системы (6)

e_4	•	•					•
e_2		•	•				
e_1			•	•	•		
e_8			I	D			•
e_3					•	•	•
e_9					I	D	
e_7							•
e_5			•				
e_6					•		
	x_7	x_6	x_1	x_2	x_3	x_4	x_5

Рис. 8. Сокращенная структурная матрица (диагностическая модель) системы (6)

В соответствии с рис. 8 недоопределенной части M^- у модели нет. Определенная часть позволяет однозначно определить входящие неизвестные, а переопределенная составляет основу для диагностирования.

3.2. Анализ диагностируемости отказов

Под диагностируемостью отказа понимают совокупность двух свойств:

- обнаруживаемость отказа – потенциальная возможность установить факт его наличия,
- локализуемость⁵ отказа – потенциальная возможность определения вида, места и времени возникновения обнаруженного отказа.

Набор обнаруживаемых и локализуемых (различаемых друг от друга) отказов в системе зависит от физических особенностей системы и ее взаимосвязей, а также от имеющихся измерений. Обнаруживаемость и локализуемость отказов – это свойства системы, накладывающие ограничения на производительность диагностирования, которая может быть достигнута любой системой диагностирования.

Без потери общности предполагается, что один отказ f_i может нарушить одно уравнение e_j модели. Если это не так, то путем введения дополнительных уравнений запись приводят к соответствующему виду.

⁵ Иногда этот термин используют с другим толкованием, а именно как предотвращение распространения влияния отказа [51]. Встречается также синоним «изолируемость» [52]. В данном случае понимание термина «локализуемость» увязано со сноской 4.

Пусть для модели M множество O_f обозначает множество всех наблюдений ее функционирования при наличии отказа f , в то время как O_{NF} – множество наблюдений при отсутствии отказов. Тогда со всей очевидностью отказ f в модели M является обнаруживаемым, если выполняется условие⁶ $O_f \setminus O_{NF} \neq \emptyset$.

Из этого вытекает утверждение, что структурно обнаруживаемый отказ f влияет на уравнение e_f , расположенное в переопределенной части M^+ модели

$$e_f \in M^+.$$

Применительно к модели (6) фрагмент декомпозиции Дулмаджа – Мендельсона принимает вид, показанный на рис. 9, где видно, что в переопределенную часть M^+ (выделена серым цветом) модели входят отказы $f_1, \dots, f_4$, в то время как отказ f_5 (f_{load}) не является обнаруживаемым ($e_{f_5} \in M^0$).

Считается, что отказ f_i локализуем (и отличим от отказа f_j), если существует наблюдение, соответствующее отказу f_i (позволяющее его обнаружить) и не связанное с отказом f_j . Сказанное записывается формулой $O_i \setminus O_j \neq \emptyset$ или

$$e_{f_i} \in (M \setminus \{e_{f_j}\})^+.$$

Обнаружение является необходимым условием локализации, т. е. из локализуемости отказа всегда следует его обнаруживаемость, но не наоборот:

$$e_{f_i} \in (M \setminus \{e_{f_j}\})^+ \Rightarrow e_f \in M^+.$$

Для иллюстрации локализуемости на примере (6) следует продолжить декомпозицию Дулмаджа – Мендельсона до результата, показанного на рис. 10.

Анализ рис. 10 показывает, что обнаруживаемые отказы f_1 и f_2 (f_R и f_h) входят в один переопределенный блок (обозначим его M_1^+), а отказы f_3 и f_4 (f_ω и f_T) – в другой переопределенный блок M_2^+ . Таким образом, указанные группы отказов изолируются друг от друга, но внутри групп они не изолируются.

⁶ Читается: множество наблюдений за вычетом наблюдений, соответствующих безотказному функционированию, не пусто.

e_4	•	•					•						•
e_2		•	•										
e_1			•	•	•			•					
e_8			I	D			•						
e_3					•	•	•						
e_9					I	D							
e_7							•					•	
e_5			•						•				
e_6					•					•			
	x_7	x_6	x_1	x_2	x_3	x_4	x_5	f_1	f_2	f_3	f_4	f_5	

Рис. 9. Структурная матрица (обнаруживаемость отказов) системы (6)

e_4	•	•				•							•
e_2		•	•										
e_1			•	•			•	•					
e_5			•						•				
e_8			I	D									
e_3					•	•	•						
e_7						•					•		
e_9					D		I						
e_6							•			•			
	x_7	x_6	x_1	x_2	x_4	x_5	x_3	f_1	f_2	f_3	f_4	f_5	

Рис. 10. Структурная матрица (локализуемость отказов) системы (6)

В целом же локализуемость одиночного отказа может быть вычислена путем анализа упорядоченных пар отказов по формуле

$$\bigcap_{f_j \in F} \left\{ (f_i, f_j) \mid e_{f_i} \in (M \setminus \{e_{f_j}\})^+ \right\}$$

с выполнением по одной декомпозиции Дулмаджа – Мендельсона для каждого отказа в модели. Таким образом, для модели в целом требуется выполнить столько декомпозиций Дулмаджа – Мендельсона, сколько анализируется одиночных отказов системы.

Для реализации потенциальных обнаруживаемости и локализуемости требуются соответствующие наблюдения. Методы структурного анализа позволяют проанализировать располагаемые наблюдения, например, показанные в модели (6) и на рис. 6. Кроме того, имеется возможность решать задачи размещения датчиков с достижением заданного или возможного уровня обнаруживаемости и локализуемости отказов, а также форми-

рования рекомендаций для построения диагностических тестов.

3.3. Обнаружение неисправностей на основе структурного анализа

Известны различные модификации структурного анализа [53] и описания алгоритмов их реализации [54]. В основном используются механизмы формирования и анализа структурно переопределенных множеств (СПМ) M^+ или, точнее, минимального СПМ, когда любое его подмножество не является СПМ. Последнее может быть достигнуто путем разбиения множества M на классы эквивалентности [16] по фигурирующим уравнениям e_i для исключения поиска одного и того же СПМ различными способами.

В результате каждый СПМ содержит набор уравнений, где по меньшей мере одно из них может использоваться для аналитической записи выражения для невязки. Набор уравнений с соответ-

ствующим разрешением относительно неизвестных используется для проектирования генератора невязки.

Для иллюстрации рассмотрим СПМ $M = \{e_1, e_3, e_5, e_7, e_8, e_9\}$ на примере электродвигателя, описываемого моделью (6). Этот набор имеет пять переменных в шести уравнениях, и любое из уравнений может быть использовано для формирования невязки. На рис. 11 показаны графы вычислений при выборе e_5 , e_1 или e_3 соответственно в качестве избыточного уравнения. Так, на рис. 11, а показан вычислительный поток от дифференцированной переменной ω' к недифференцированной переменной ω , т. е. интегрирование. На рис. 11, б – противоположный случай, от h к h' , т. е. дифференцирование. И, наконец, на рис. 11, в – оба случая, интегрирование и дифференцирование.

На схемах рис. 11 использованы обозначения: на левом краю входные переменные, вертикальная черта – разрешение указанного уравнения относительно последующей переменной.

Каждая из показанных схем обладает своими вычислительными особенностями и получаемой чувствительностью невязки к неисправным состояниям.

Получим итоговую расчетную формулу диагностирования на основе, например, схемы рис. 11, в. Эта формула определяет содержание любого реализуемого варианта алгоритма. Выполняя соответствующие схеме подстановки, вводя оператор дифференцирования по времени

$p = d/dt$ и выполняя простые преобразования, получаем «точное» выражение для невязки

$$r = \frac{Jp+b}{K_a} \left(\frac{U}{y_h - f_h} - Lp \ln(y_h - f_h) - R - f_R \right) - y_T + f_T.$$

Однако отказы f_h , f_R и f_T по определению недоступны для непосредственного измерения, и, таким образом, реализуемая формула невязки в окрестности точки $f_h = 0$, $f_R = 0$ и $f_T = 0$, приведенной к сигналу датчика момента на валу двигателя, принимает вид

$$r(f_h, f_R, f_T) = \frac{Jp+b}{K_a} \left(\frac{U}{y_h} - Lp \ln(y_h) - R \right) - y_T, \quad (7)$$

в соответствии с которым для обнаружения по крайней мере отдельных отказов f_h , f_R и f_T используются измеряемые сигналы U , y_h и y_T . При отсутствии отказов равенство (7) принимает нулевое значение. Значения параметров системы J , b , K_a , L и номинальное (безотказное) значение R должны быть известны.

Чувствительность к «постоянным» отказам ($pf_h = 0$, $pf_R = 0$, $pf_T = 0$) характеризуется значениями

$$\frac{\partial r}{\partial f_h} = \frac{Jp+b}{K_a} \left(Lp \frac{1}{y_h} - U \frac{1}{y_h^2} \right), \quad \frac{\partial r}{\partial f_R} = -\frac{b}{K_a}, \quad \frac{\partial r}{\partial f_T} = 1,$$




Рис. 11. Схемы СПМ с вариантами формирования невязок: а – интегральным, б – смешанным, в – дифференциальным

откуда следует, что в случае изменения сигнала датчика тока y_h обмотки двигателя в соответствии с нелинейным дифференциальным уравнением

$$JLp^2 \frac{1}{y_h} + bLp \frac{1}{y_h} - JU p \frac{1}{y_h^2} - bU \frac{1}{y_h^2} = 0$$

достаточное условие $\partial r / \partial f_h \neq 0$ чувствительности (7) к отказу f_h не будет удовлетворено.

Последнее обстоятельство указывает на то, что на определенных фазовых траекториях движения системы диагностирование может не выполняться⁷.

4. МЕТОДЫ ДИАГНОСТИРОВАНИЯ НА ОСНОВЕ АППАРАТА ТЕОРИИ МНОЖЕСТВ

При использовании моделей динамических систем в целях их мониторинга всегда существует некоторое несоответствие между результатами моделирования и реальным поведением этих систем. Такое явление обусловлено как пренебрежением некоторыми известными «несущественными» связями, так и наличием неизвестных или неточно известных связей в моделируемом объекте. Возникающие ошибки моделирования вносят неопределенность, которая чаще всего не выходит за пределы оцениваемых диапазонов.

Существует несколько способов учета неопределенности, связанной с моделью, в зависимости от того, находится ли она в параметрах (структурированная) или в структуре модели (неструктурированная). Группа наиболее развитых подходов, известных как активные, основана на генерировании невязок, нечувствительных к оговоренным неопределенностям, но чувствительных к неисправностям системы. В то же время существует другое семейство подходов, известных как пассивные, которые повышают надежность системы обнаружения неисправных состояний путем распространения неопределенности на значения невязок с созданием соответствующих адаптивных порогов⁸. Основоположающими работами, предлагающими второй из подходов, являются [55] во временной области и [27] в частотной области.

4.1. Исходные положения и постановка задачи

Идея подхода, основанного на принадлежности отказа к множеству, заключается в использовании

⁷ Это относится не только к структурным методам.

⁸ И хотя подход использует традиционные модели типа (1) [30], представленного в ч. 2 обзора, не они составляют ядро подхода.

геометрического набора для привязки неопределенных состояний. Известные геометрические наборы включают интервалы, эллипсоиды, многогранники, зонотопы и т. д. Из всех подходов с множествами зонотопы отличаются наименьшей вычислительной сложностью при реализации.

Излагаемый подход оперирует специфическим понятием и обозначениями зонотопа – математической конструкцией⁹ вида

$$Z = \langle c, H \rangle = \{c + Hz, \|z\|_\infty \leq 1\}, \quad (8)$$

где c и H – центр и сегментная матрица зонотопа. Запись (8) используется для формального обозначения интервала в многомерном пространстве. На плоскости это прямоугольник со сторонами $2h_1$ и $2h_2$, в трехмерном пространстве – параллелепипед с ребрами $2h_1$, $2h_2$, $2h_3$ и т. д.

Для зонотопов характерна линейность в смысле

$$\langle c_1, H_1 \rangle \oplus \langle c_2, H_2 \rangle = \langle c_1 + c_2, [H_1, H_2] \rangle,$$

$$L \langle c, H \rangle = \langle Lc, LH \rangle,$$

где $\oplus$ – сумма Минковского¹⁰; L – произвольная матрица соответствующего размера. Здесь $[H_1, H_2]$ обозначает формирование новой сегментной матрицы из исходных H_1 и H_2 , которое, как правило, приводит к «разрастанию» границ зонотопа.

В работе [56] для зонотопа $Z = \langle c, H \rangle$ предлагается оператор взвешенной редукции, обозначаемый $\downarrow_{q,w}^H$ и удовлетворяющий следующему свойству:

$$\langle c, \downarrow_{q,w}^H \rangle \subseteq \langle c, H \rangle,$$

где $q \geq n$ обозначает максимальное число столбцов $\downarrow_{q,w}^H$, а W – весовая матрица соответствующего размера. Использование такой редукции позволяет сокращать сегментную матрицу, определяющую «разброс» возможных значений в окрестности центра зонотопа.

Рассматривается линейная система с дискретным временем $t = 0, 1, 2, \dots$

$$x_{t+1} = Ax_t + Bu_t + D_w w_t, \quad y_t = Cx_t + D_v v_t, \quad (9)$$

⁹ Многогранник, представляющий собой сумму Минковского множества векторов.

¹⁰ Суммой Минковского множеств A и B линейного пространства V называется множество C , состоящее из сумм всевозможных векторов из A и B : $C = \{c | c = a + b, a \in A, b \in B\}$, см. статью [57].



где $x_t \in \mathbb{R}^{n_x}$, $u_t \in \mathbb{R}^{m_u}$ и $y_t \in \mathbb{R}^{n_y}$ – векторы состояний системы, известные входы и выходы соответственно; $w_t \in \mathbb{R}^{m_w}$ и $v_t \in \mathbb{R}^{m_v}$ – векторы возмущений и шума измерения соответственно.

Значения векторов w_t , v_t и начальное состояние x_0 ограничены зонотопами¹¹

$$w_t \in \langle 0, I_{m_w} \rangle, v_t \in \langle 0, I_{m_v} \rangle, x_0 \in X_0 = \langle c_0, H_0 \rangle \quad (10)$$

и на каждом такте полагаются неизвестными.

4.2. Зонотопический наблюдатель

Здесь кратко излагается один из подходов к диагностированию с использованием зонотопов [16, 49].

Для системы (9) вводится наблюдатель с коэффициентом усиления $G(k) \in \mathbb{R}^{n_x \times n_y}$:

$$\hat{x}_{t+1} = A\hat{x}_t + Bu_t + D_w w_t + G_t(y_t - C\hat{x}_t - D_v v_t). \quad (11)$$

Утверждается [58], что для наблюдателя (11) при $\forall t+1 \in N$ справедливо включение

$$\hat{x}_{t+1} \in \mathbb{S}_{t+1} = \langle c_{t+1}, H_{t+1} \rangle, \quad (12)$$

где центр и матрица сегментов определяются формулами

$$\begin{aligned} c_{t+1} &= (A - G_t C)c_t + Bu_t + G_t y_t, \\ H_{t+1} &= \left[(A - G_t C) \downarrow_{q,w}^H, D_w, G_t D_v \right]. \end{aligned} \quad (13)$$

Согласно формулам (13) включение (12) раскрывается следующим образом:

$$\begin{aligned} \hat{x}_{t+1} \in \langle c_{t+1}, H_{t+1} \rangle &= \\ &= \left((A - G_t C) \langle c_t, \downarrow_{q,w}^H \rangle \right) \oplus \\ &\oplus (B \langle u_t, 0 \rangle) \oplus (C_t \langle y_t, 0 \rangle) \oplus \\ &\oplus (D_w \langle 0, I_{m_w} \rangle) \oplus (-G_t D_v \langle 0, I_{m_v} \rangle). \end{aligned} \quad (14)$$

Формула (14) определяет потактовую трансформацию зонотопа, ограничивающего последующие значения вектора $\hat{x}_t$, $\forall t+1 \in N$.

4.3. Обнаружение неисправностей

Для обнаружения наличия неисправностей в системе, когда вместо формул (9) действуют уравнения

$$\begin{aligned} x_{t+1} &= Ax_t + Bu_t + D_w w_t + Q^u f_t^u, \\ y_t &= Cx_t + D_v v_t + Q^y f_t^y, \end{aligned} \quad (15)$$

где $f_t \in \mathbb{R}^{m_f}$ и $Q \in \mathbb{R}^{n_y \times m_f}$ – вектор и матрица влияния неисправностей актюатора (верхний индекс u) и датчика (верхний индекс y) соответственно, выполняются следующие действия:

– получение и хранение данных ввода – вывода

$$U_t = \{u_t\} \text{ и } Y_t = \{y_t\},$$

– вычисление множества оцененных состояний

$Y_t = \{y_t\}$ с использованием уравнения (14) и интервальных ограничений (10)

$$X_0, u_t, y_t, w_t, v_t \rightarrow X_t^e,$$

– вычисление множества оцененных выходов

Y_t^e с использованием второго уравнения (9) и интервальных ограничений (10)

$$X_t^e, v_t \rightarrow Y_t^e,$$

– вычисление пересечения множеств оцененных и измеренных выходов

$$X_t^{f=0} = Y_t^e \cap Y_t. \quad (16)$$

Если для каждого t пересечение (16) не пусто, то считается, что реальное значение выхода системы совпадает с его прогнозом, поэтому делается заключение об отсутствии неисправностей. Пустота такого пересечения является признаком наличия неисправностей в системе.

При этом условие чувствительности теста (16) к неисправностям датчика в уравнениях (15) выглядит как нестрогое неравенство

$$\sum_{t=0}^{\infty} (c_t^{rf})^T c_t^{rf} \geq \beta_s^2 \sum_{t=0}^{\infty} f_t^T f_t \quad (17)$$

при существовании таких матриц¹² $P \in S_{>0}^{n_x}$, $K \in \mathbb{R}^{n_x \times n_y}$, $N \in \mathbb{R}^{n_y \times n_y}$ и скаляров $\alpha > 0$, $\beta > 0$, что имеет место положительная определенность матрицы¹³

$$\begin{bmatrix} \alpha P & * & * \\ \alpha A^T P - \alpha C^T K^T & \alpha P + C^T N C & * \\ -\alpha Q^T K^T & Q^T N^T C & Q^T N Q - \beta^2 I_{m_f} \end{bmatrix} \succ 0.$$

Здесь c_t^{rf} – центр зонотопа $R_t = \langle c_t^r, H_t^r \rangle$, $\forall t \in N$, невязки $r_t^f = y_t - Cx_t$ с параметрами

$$c_t^r = M(y_t - Cc_t), \quad H_t^r = [MCH_t \quad MD_v],$$

¹² Первая из них положительно определенная симметрическая, $P \succ 0$.

¹³ Здесь звездочки использованы для упрощения записи симметрической матрицы.

¹¹ Первые два зонотопа называются унитарными.

где $M \in \mathcal{R}^{n_y \times n_y}$ – матрица усиления зонотопа невязки, в качестве варианта можно использовать равенства $G = P^{-1}K$, $M = N^2$.

Соответствующие доказательства и примеры использования зонотопов можно найти в [51, 59].

5. СТАТИСТИЧЕСКОЕ ДИАГНОСТИРОВАНИЕ

В основе подхода диагностирования по типу распознавания образов лежит метод статистических решений, заключающийся в следующем.

Рассматривается система с дискретным пространством признаков (измерений) размерности k с осями $\xi_1, \xi_2, \dots, \xi_k$ и числом градаций n по осям $\pi_1, \pi_2, \dots, \pi_n$ соответственно. Градации предусматривают как исправное техническое состояние системы, так и наличие различных неисправностей. Далее предполагается, что таких систем достаточно много¹⁴, и в зависимости от соответствующих признаков они разделяются на классы K_{ij} , $i=1, k$, $j=1, n$, включая варианты без неисправностей $K_{испр}$ или с различными неисправностями $K_{m-я\text{ неисправ}}$, где $m \leq kn-1$.

Основным параметром является эмпирическая (статистическая) оценка отношения правдоподобия, в одной из редакций (упрощенной, дающей «локальную» оценку) метода вычисляемая по формуле [60]

$$L(\xi) = \frac{f_l(\xi)}{f_h(\xi)} \approx \frac{r_l + 1}{r_h + 1} \frac{N_h + 2}{N_l + 2}, \quad (18)$$

где $f_l(\xi)$ и $f_h(\xi)$ – байесовы оценки вероятностей попадания системы из l -го или h -го классов соответственно в некоторую точку ξ (или окрестность ее); r_l и r_h – число систем l -го и h -го классов, попавших в точку ξ по априорной информации; N_l и N_h – число систем l -го или h -го классов обучающей выборки. Более точные, но сложные формулы с использованием плотностей вероятности можно найти в работах [60, 61].

Для принятия решения о принадлежности системы к тому или иному классу используется пороговое правило типа

- система исправна, если $L(\xi) \in K_{испр}$,

- у системы m -я неисправность, если

$$L(\xi) \in K_{m-я\text{ неисправ}}.$$

¹⁴ С учетом гипотезы об эргодичности случайных процессов [62], для априорных данных это число используемых для обучения систем, а для апостериорных данных – число разнесенных во времени наблюдений диагностируемой системы.

Этап обучения заключается в запоминании систем из обучающей выборки, а вычисление (18) производится при текущем осуществлении распознавания (диагностировании).

Таким образом, формально решение задачи диагностирования (прогнозирование) с помощью математического аппарата статистической классификации не имеет принципиальных отличий от решения других технических задач, требующих распознавания, но существует ряд специфических особенностей, которые необходимо учитывать. Основные этапы решения задачи включают:

- выбор модели распознавания, которая может быть детерминированной или вероятностной и зависит от того, насколько перемешаны множества, принадлежащие к разным классам;
- описание эталонов классов R_λ (исправен и разные неисправности) на основе априорной информации, оценка информативности (значимости для распознавания) параметров позволяет оптимизировать описание эталонов;
- сопоставление текущей информации о контролируемой системе с априорно заданными эталонами классов R_λ ;
- принятие решения о степени работоспособности системы или ее частей по данным контроля.

Основная особенность статистического подхода заключается в том, что для приемлемой результативности его применения требуется значительный объем как априорных (обучающих), так и апостериорных (текущих контрольных измерений) данных. Тем не менее, использование «локальной» оценки (18) позволяет решать задачи с числом параметров (используемых измерений) $k \leq 50$ и числом градаций (связано с количеством возможных неисправностей) по каждому параметру $\pi \leq 8$, т. е. речь идет о не слишком больших выборках, что принципиально для задач мониторинга.

Статистическое диагностирование на основе распознавания образов получило широкое распространение и развитие в отечественной научной литературе и технике, см., например, работы [63–65].

ЗАКЛЮЧЕНИЕ

Привлечение средств представления или описания динамических систем неклассического типа в целом значительно расширило возможности их диагностирования, прежде всего в смысле обхода традиционных для технических приложений трудностей: зашумленности реальных измерений и искажений, неизбежно вносимых в формальные модели. В результате были созданы и получили распространение системы диагностирования и мони-



торинга с принципиально новыми возможностями и областями практического применения.

В то же время этот путь таит в себе дополнительные проблемы: помимо усложнения применяемого аппарата получаемый результат может обладать непрозрачностью, расплывчатостью, неоднозначностью или чрезмерной общностью. Недостаточная конкретика может оказаться серьезным ограничением применения соответствующих подходов.

Четвертая часть обзора будет посвящена анализу новых подходов к диагностированию и объединению различных моделей и методов.

ЛИТЕРАТУРА

1. *Forssell, U., Ljung, L.* Closed-Loop Identification Revisited // *Automatica*. – 1999. – Vol. 35, no. 7. – P. 1215–1241.
2. *Haber, R. and Unbehauen, H.* Structure Identification of Non-linear Dynamic Systems – A Survey on Input/Output Approaches // *Automatica*. – 1990. – Vol. 26, no. 7. – P. 651–677.
3. *Isermann, R.* Fault-Diagnosis Systems. An Introduction from Fault Detection to Fault Tolerance. – Berlin, Heidelberg: Springer, 2006.
4. *Калявин В.П., Давыдов Н.А.* Надежность и диагностика автомобилотранспортных средств. – СПб.: Элмор, 2014. [*Kalyavin, V.P., Davydov, N.A.* Reliability and Diagnostics of Motor Vehicles. – St. Petersburg: Elmore, 2014. (In Russian)]
5. *Палюх Б.В., Богатиков В.Н., Шпрехер Д.М.* Диагностирование электромеханических систем на основе нейросетевых технологий // Программные продукты и системы. – 2015. – № 3. – С. 5–11. [*Palyukh, B.V., Shprekher, D.M., and Bogatikov, V.N.* Electromechanical Systems Diagnosis Based on Neural Network Technologies // *Software & Systems*. – 2015. – No. 3. – P. 5–11. (In Russian)]
6. *Пушкарев Д.О.* Применение нейросетевых экспертных систем для контроля, диагностики и прогнозирования технического состояния авиационных двигателей // Информационно-технологический вестник. – 2020. – № 3 (25). – С. 51–59. [*Pushkarev, D.O.* Application of Neural Network Expert Systems for Monitoring, Diagnostics and Forecasting the Technical Condition of Aircraft Engines // *Information Technology Bulletin*. – 2020. – No. 3 (25). – P. 51–59. (In Russian)]
7. *Кулида Е.Л., Лебедев В.Г.* Современные подходы к диагностике и прогнозированию технического состояния электромеханического привода летательного аппарата // Проблемы управления. – 2024. – № 3. – С. 3–19. [*Kulida, E.L., Lebedev, V.G.* Modern Approaches to Prognostics and Health Management of an Aircraft Electromechanical Actuator // *Control Sciences*. – 2024. – No. 3. – P. 3–15.]
8. *Vasilescu, M.-V., Epikhin, A.I., Toriya, T.G.* Diagnostics of the Technical Condition of a Boiler Plant Using Bayesian Networks // *Эксплуатация морского транспорта*. – 2023. – № 3. – С. 113–120. [*Vasilescu, M.-V., Epikhin, A.I., Toriya, T.G.* Diagnostics of the Technical Condition of a Boiler Plant Using Bayesian Networks // *Ekspluatatsiya morskogo transporta*. – 2023. – No. 3. – P. 113–120.]
9. *Лоскутов А. И., Столяров А. В., Ряхова Е.А.* Способ контроля технического состояния бортовой радиоэлектронной аппаратуры космических аппаратов на основе взаимодействия элементов распределенной системы технического диагностирования // Контроль. Диагностика. – 2021. – Т. 24, № 1 (271). – С. 44–50. [*Loskutov, A.I., Stolyarov, A.V., Ryakhova, E.A.* Method for Control of Technical State of Onboard Radioelectronic Equipment of Spacecrafts Based On Interaction of Elements of Distributed Technical Diagnosis System // *Testing. Control. Diagnostics*. – 2021. – Vol. 24, no. 1 (271). – P. 44–50. (In Russian)]
10. *Haykin, S.S.* Neural Networks and Learning Machines. Vol. 3. – Upper Saddle River, NJ: Pearson Education, 2009.
11. *Diaconescu, E.* The Use of NARX Neural Networks to Predict Chaotic Time Series // *WSEAS Trans. Comp. Research*. – 2008. – Vol. 3. – P. 182–191.
12. *Liu, G.P., Patton, R.J.* Eigenstructure Assignment for Control System Design. – New York: John Wiley & Sons, 1998.
13. *Medsker, L., Jain, L.C.* Recurrent Neural Networks: Design and Applications. – Cleveland: CRC Press, 1999.
14. *Круглов В.В., Борисов В.В.* Искусственные нейронные сети. Теория и практика. – М.: Горячая линия – Телеком, 2002. [*Kruglov, V.V., Borisov, V.V.* Iskusstvennyye neironnyye seti. Teoriya i praktika. – M.: Goryachaya liniya – Telekom, 2002. (In Russian)]
15. *Рейзлин В.И.* Численные методы оптимизации: учебное пособие. – Томск: Изд-во НИТПУ, 2013. [*Reizlin, V.I.* Chislennyye metody optimizatsii: uchebnoye posobie. – Tomsk: Izd-vo NITPU, 2013. (In Russian)]
16. *Krysander, M., Eslund, J., Nyberg, M.* An Efficient Algorithm for Finding Minimal Overconstrained Subsystems for Model-Based Diagnosis // *IEEE Transactions on Systems, Man, and Cybernetics – Part A: Systems and Humans*. – 2008. – Vol. 38, no. 1. – P. 197–206.
17. *Korbicz, J., Patan, K., Obuchowicz, A.* Dynamic Neural Network for Process Modelling in Fault Detection and Isolation Systems // *Applied Mathematics and Computer Science*. – 1999. – Vol. 9, no. 2. – P. 519–546.
18. *Dexter, A.L., Benouarets, M.* Model-Based Fault Diagnosis Using Fuzzy Matching // *IEEE Trans. on Sys. Man. and Cyber. Part A: Sys. & Humans*. – 1997. – Vol. 27, no. 5. – P. 673–682.
19. *Isermann, R.* On Fuzzy Logic Applications for Automatic Control, Supervision and Fault Diagnosis // *IEEE Trans. on Sys. Man. and Cyber. Part A: Sys. & Humans*. – 1998. – Vol. 28, no. 2. – P. 221–235.
20. *Полковникова Н.А., Курейчик В.М.* Нейросетевые технологии, нечёткая кластеризация и генетические алгоритмы в экспертной системе // Известия ЮФУ. Технические науки. – 2014. – № 7 (156). – С. 7–15. [*Polkovnikova, N.A., Kureichik, V.M.* Neural Network Technologies, Fuzzy Clustering and Genetic Algorithms in an Expert System // *Bulletin of SFedU. Technical sciences*. – 2014. – No. 7 (156). – P. 7–15. (In Russian)]
21. *Ахметханов Р.С., Дубинин Е.Ф., Куксова В.И.* Использование методов и моделей нечеткой логики в системах технической диагностики // Приводы и компоненты машин. – 2018. – № 1–2 (27). – С. 6–11. [*Akhmetkhanov, R.S., Dubinin, E.F., Kuksova, V.I.* Use of Fuzzy Logic Methods and Models in Technical Diagnostics Systems // *Drives and Machine Components*. – 2018. – No. 1–2 (27). – P. 6–11. (In Russian)]
22. *Шумский А.Е., Жирабок А.Н.* Метод функционального диагностирования дискретно-событийных систем на основе модели нечеткого конечного автомата // Проблемы управления. – 2025. – № 2. – С. 38–49. [*Shumsky, A.E., Zhirabok, A.N.* A Fault Diagnosis Method for Discrete-Event Systems Based on the Fuzzy Finite State Automaton Model // *Control Sciences*. – 2025. – No. 2. – P. 31–41.]

23. Ключкин А. К., Хаматов А. А. Синтез диагностической модели на основе аппарата нечеткой логики // *Авиакосмическое приборостроение*. – 2023. – № 7. – С. 34–41. [Klyuchkin A. K., Khamatov A. A. Sintez diagnosticheskoi modeli na osnove apparata nechetkoi logiki // *Aviakosmicheskoe priborostroenie*. – 2023. – № 7. – S. 34–41. (In Russian)]
24. Аблязов Э.К., Аблязов К.А. Оценка технического состояния портового подъемно-транспортного оборудования (ПТО) с использованием нечеткой логики // *Морские интеллектуальные технологии*. – 2024. – № 2-1 (64). – С. 242–251. [Ablyazov E.K., Ablyazov K.A. Otsenka tekhnicheskogo sostoyaniya portovogo pod'emno-transportnogo oborudovaniya (PTO) s ispol'zovaniem nechetkoi logiki // *Morskie intellektual'nye tekhnologii*. – 2024. – No. 2-1 (64). – S. 242–251. (In Russian)]
25. Fantuzzi, C., Rovatti, R. On the Approximation Capabilities of the Homogeneous Takagi-Sugeno Model // *Proceedings of the 5th IEEE International Conference on Fuzzy Systems*. – Vol. 2. – NJ: IEEE, Piscataway, 1996. – P. 1067–1072.
26. Rovatti, R. Takagi-Sugeno Models as Approximators in Sobolev Norms: The SISO Case // *Proceedings of the 5th IEEE International Conference on Fuzzy Systems*. – Vol. 2. – NJ: IEEE, Piscataway, 1996. – P. 1060–1066.
27. Takagi, T., Sugeno, M. Fuzzy Identification of Systems and Its Applications to Modeling and Control // *IEEE Transactions on Systems, Man and Cybernetics*. – 1985. – No. 1. – P. 116–132.
28. Jun, W., Shitong, W., Chung, F.-L. Positive and Negative Fuzzy Rule System, Extreme Learning Machine and Image Classification // *Int. J. of Machine Learning and Cybernetics*. – 2011. – No. 2 (4). – P. 261–271.
29. Graaff, A.J., Engelbrecht, A.P. Clustering Data in Stationary Environments with a Local Network Neighborhood Artificial Immune System // *Int. J. of Machine Learning and Cybernetics*. – 2012. – Vol. 3, no. 1. – P. 1–26.
30. Буков В.Н., Бронников А.М., Попов А.С., Шурман В.А. Методы мониторинга технического состояния систем в целях управления их избыточностью. Ч. 2. Классические модели // *Проблемы управления*. – 2025. – № 3. – С. 3–14. [Bukov, V.N., Bronnikov, A.M., Popov, A.S., Shurman, V.A. Technical Condition Monitoring Methods to Manage the Redundancy of Systems. Part II: Classical Models // *Control Sciences*. – 2025. – No. 3. – P. 2-11.]
31. *Diagnosis and Fault-Tolerant Control 2: From Fault Diagnosis to Fault-Tolerant Control* / Coord. by V. Puig and S. Simani. London: ISTE Ltd, Hoboken: John Wiley & Sons Inc, 2021.
32. Bezdek, J.C. *Pattern Recognition with Fuzzy Objective Function Algorithms*. – Berlin: Springer Science & Business Media, 2013. –
33. Chow, E.Y., Willsky, A.S. Analytical Redundancy and the Design of Robust Detection Systems // *IEEE Trans. Automatic Control*. – 1984. – Vol. 29, no. 7. – P. 603–614.
34. Duan, G., How, D., Patton, R. Robust Fault Detection in Descriptor Systems via Generalised Unknown Input Observers // *Int. J. Systems Science*. – 2002. – Vol. 32, no. 2. – P. 7724–7729.
35. Zaytoon, J., Lafortune, S. Overview of Fault Diagnosis Methods for Discrete Event Systems // *Annual Reviews in Control*. – 2013. – Vol. 37, no. 2. – P. 308–320.
36. Cassandra, Ch., Lafortune, S. *Introduction to Discrete Event Systems*. 2nd edition. – New York: Springer Science+Business Media, LLC, 2008. – 770 p.
37. Журабок А.Н., Калинина Н.А., Шумский А.Е. Метод мониторинга поведения человека-оператора в человеко-машинных системах // *Известия РАН. Теория и системы управления*. – 2018. – № 3. – С. 98–107. [Zhirabok, A.N., Kalinina, N.A., Shumskii, A.E. Technique of Monitoring a Human Operator's Behavior in Man-Machine Systems // *Journal of Computer and Systems Sciences International*. – 2018. – Vol. 57, no. 3. – P. 443–452.]
38. Журабок А.Н., Калинина Н.А., Шумский А.Е. Метод функционального диагностирования недетерминированных конечных автоматов // *Известия РАН. Теория и системы управления*. – 2020. – № 4. – С. 62–72. [Zhirabok, A.N., Kalinina, N.A., Shumskii, A.E. Method for the Functional Diagnosis of Nondeterministic Finite State Machines // *Journal of Computer and Systems Sciences International*. – 2020. – Vol. 59, no. 4. – P. 565–574.]
39. Kościelny, J.M. Application of Fuzzy Logic for Fault Isolation in a Three-Tank System // *Proc. 14th IFAC World Congress. Beijing*. – 1999. – Vol. 7. – P. 73–78.
40. Hengy, D., Frank, P.M. Component Failure Detection Using Local Second-Order Observers // *Fault Detection & Reliability* / Ed. by M.G. Singh. – Oxford: Pergamon Press, 1987. – P. 147–154.
41. Frank, P.M. Fault Diagnosis in Dynamic Systems via State Estimation – A Survey // In: *System Fault Diagnosis, Reliability and Related Knowledge-Based Approaches* / Ed. by E.A. Tzafestas. – Dordrecht: Dr. Reidel Publ. Comp., 1987. – Vol. 1. – P. 35–98.
42. Koenig, D., Nowakowski, S., Cecchin, T. An Original Approach for Actuator and Component Fault Detection and Isolation // *Proceedings of the CAA Symposium on Fault Detection, Supervision and Safety for Technical Processes SAFEPROCESS '97*. – Kingston upon Hull, 1997. – Vol. 1. – P. 95–105.
43. Garcia, F.I., Izquierdo, V., de Miguel, L., Peran, J. Fuzzy Identification of Systems and Its Applications to Fault Diagnosis Systems // *Proceedings of the CAA Symposium on Fault Detection, Supervision and Safety for Technical Processes SAFEPROCESS '97*. – Kingston upon Hull, 1997. – Vol. 2. – P. 705–712.
44. Koscielny, J.M., Sedziak, D., Sikora, A. The “DIAG” System for Fault Detection and Isolation in Industrial Processes // *Proceedings of the CAA Symposium on Fault Detection, Supervision and Safety for Technical Processes SAFEPROCESS '94*. – Helsinki, 1994. – Vol. 2. – P. 790–795.
45. Han, Z., Frank, P.M. Physical Parameter Estimation Based FDI with Neural Networks // *Proceedings of the CAA Symposium on Fault Detection, Supervision and Safety for Technical Processes SAFEPROCESS '97*. – Kingston upon Hull, 1997. – Vol. 1. – P. 294–299.
46. Benkbedda, H., Patton, R. Information Fusion in Fault Diagnosis Based on B-spline Networks // *Proceedings of the CAA Symposium on Fault Detection, Supervision and Safety for Technical Processes “SAFEPROCESS'97”*. – Kingston upon Hull, 1997. – Vol. 2. – P. 681–686.
47. Cassar, J.P., Staroswiecki, M. A Structural Approach for the Design of Failure Detection and Identification Systems // *IFAC Proceedings Volumes*. – 1997. – Vol. 30, no. 6. – P. 841–846.
48. Ploix, S., Désinde, M., Touaf, S. Automatic Design of Detection Tests in Complex Dynamic Systems // *IFAC Proceedings volumes*. – 2005. – Vol. 38, no. 1. – P. 478–483.
49. *Diagnosis and Fault-tolerant Control 1: Data-Driven and Model-Based Fault Diagnosis Techniques* / Coord. by V. Puig and S. Simani. – London: ISTE Ltd, Hoboken: John Wiley & Sons Inc, 2021.
50. Копкин Е.В., Иваню А.Ю. Структурно-стохастическая вычислительная модель контроля технического состояния бортовых систем космических аппаратов // *Изв. Тульского*



- государственного университета. Технические науки. – 2022. – № 10. – С. 9–14. [Kopkin, E.V., Ivanju, A.Ju. Strukturno-stohasticheskaja vychislitel'naja model' kontrolja tehničeskogo sostojanija bortovyh sistem kosmicheskikh apparatov // Izv. Tul'skogo gosudarstvennogo universiteta. Tehničeskije nauki. – 2022. – No. 10. – P. 9–14. (In Russian)]
51. *Рекомендации по стандартизации Р 50.1.048-2004*: Информационно-телекоммуникационные игровые системы. Термины и определения. – Москва: Госстандарт России, 2004. – 19 с. [Rekomendatsii po standartizatsii R 50.1.048-2004: Informatsionno-telekommunikatsionnye igrovyje sistemy. Terminy i opredeleniya. – Moskva: Gosstandart Rossii, 2004. – 19 s. (In Russian)]
52. Брускин С.Н., Дружаев А.А., Марон А.И., Марон М.А. Эффективные методы построения алгоритмов поиска неисправностей в информационных системах // Интеллектуальные системы в производстве. – 2017. – № 15 (3). – С. 88–93. [Bruskin, S.N., Druzhaev, A.A., Maron, A.I., Maron, M.A. Jeffektivnye metody postroenija algoritmov poiska neispravnostej v informacionnyh sistemah // Intel'ktual'nye sistemy v proizvodstve. – 2017. – No. 15 (3). – P. 88–93. (In Russian)]
53. Armengol, J., Bregyn, A., Escobet, T., et al. Minimal Structurally Overdetermined Sets for Residual Generation: A Comparison of Alternative Approaches // IFAC Proceedings Volumes. – 2009. – Vol. 42, no. 8. – P. 1480–1485.
54. Krysender, M., Eslund, J., Frisk, E. A Structural Algorithm for Finding Testable Sub-models and Multiple Fault Isolability Analysis // Proceedings of 21st International Workshop on Principles of Diagnosis (DX-10). – Portland, USA, 2010. – DOI: <https://doi.org/10.36001/phmconf.2010.v2i1.1940>
55. Horak, D. Failure Detection in Dynamic Systems with Modeling Errors // AIAA J. of Guidance, Control and Dynamics. – 1988. – Vol. 11, no. 6. – P. 508–516.
56. Song, Y., Sai, M.P.D., Yu, H. Zonotope-Based Nonlinear Model Order Reduction for Fast Performance Bound Analysis of Analog Circuits with Multiple-Interval-Valued Parameter Variations // Proceedings of IEEE Design, Automation & Test in Europe: Conference & Exhibition. – Dresden, Germany, 2014. – DOI: 10.7873/DATE2014.024
57. Панюков А.В. Представление суммы Минковского для двух полиэдров системой линейных неравенств // Вестник ЮУрГУ. Серия: Математическое моделирование и программирование. – 2012. – № 14. – С. 108–119. [Panjukov, A.V. Predstavlenie summy Minkovskogo dlja dvuh polijedrov sistemoy linejnyh neravenstv // Vestnik JuUrGU. Serija: Matematicheskoe modeli-rovanie i programmirovanie. – 2012. – No. 14. – P. 108–119. (In Russian)]
58. Combastel, C. Zonotopes and Kalman Observers: Gain Optimality under Distinct Uncertainty Paradigms and Robust Convergence // Automatica. – 2015. – No. 55. – P. 265–273.
59. Himmelblau, D.M. Fault Diagnosis in Chemical and Petrochemical Processes. – Amsterdam: Elsevier, 1978.
60. Гаскаров Д.В., Голинкевич Т.А., Мозгалеvский А.В. Прогнозирование технического состояния и надежности радиоэлектронной аппаратуры / Под ред. Голинкевича Т.А. – М.: Советское радио, 1974. [Gaskarov, D.V., Golinkevich, T.A., Mozgalevskij, A.V. Prognozirovanie tehničeskogo sostojanija i nadezhnosti radiojelektronnoj apparatury / Pod red. Golinkevicha T.A. – M.: Sovetskoe radio, 1974. (In Russian)]
61. Мозгалеvский А.В., Койда А.Н. Вопросы проектирования систем диагностирования. – Л.: Энергоатомиздат, Ленингр. отделение, 1985. [Mozgalevskij, A.V., Kojda, A.N. Voprosy proektirovanija sistem diagnostirovaniya. – L.: Jenergoatomizdat, Leningr. otdelenie, 1985. (In Russian)]
62. Вентцель Е.С. Теория вероятностей. – М.: КноРус, 2010. [Ventcel', E.S. Teorija verojatnostej. – M.: KnoRus, 2010. (In Russian)]
63. Обозов А.А., Таричко В.И. Совершенствование технического диагностирования автомобильных двигателей на основе применения методов статистической теории распознавания образов // Двигателестроение. – 2013. – № 3 (253). – С. 16–22. [Obozov, A.A., Tarichko, V.I. Sovershenstvovanie tehničeskogo diagnostirovanija avtomobil'nyh dvigatelej na osnove primenija metodov statističeskoj teorii raspoznavanija obrazov // Dvigatelsestroenie. – 2013. – No. 3 (253). – P. 16–22. (In Russian)]
64. Усик Б.А., Лучин А.В., Обыночный И.А. Выбор параметров для диагностирования преобразовательных устройств с резервированными элементами методами распознавания образов // Известия Института инженерной физики. – 2022. – № 3 (65). – С. 14–16. [Usik, B.A., Luchin, A.V., Obynochnyj, I.A. Vybory parametrov dlja diagnostirovaniya preobrazovatel'nyh ustrojstv s rezervirovannymi jelementami metodami raspoznavanija obrazov // Izvestija Instituta inzhenernoj fiziki. – 2022. – No. 3 (65). – P. 14–16. (In Russian)]
65. Шамолин М.В. Обобщенная задача контроля в задачах диагностики // Итоги науки и техники. Современная математика и ее приложения. Тематические обзоры. – 2022. – Т. 209. – С. 117–126. [Shamolin, M.V. Obobshhennaja zadacha kontrolja v zadachah diagnostiki // Itogi nauki i tehniki. Sovremennaja matematika i ee prilozhenija. Tematicheskie obzory. – 2022. – Vol. 209. – P. 117–126. (In Russian)]

Статья представлена к публикации членом редколлегии
В. Г. Лебедевым.

Поступила в редакцию 13.11.2024,
после доработки 21.08.2025.
Принята к публикации 27.08.2025.

Буков Валентин Николаевич – д-р техн. наук, АО «Борт-
вые аэронавигационные системы», г. Москва,
✉ v_bukov@mail.ru,
ORCID iD: <https://orcid.org/0000-0002-5194-8251>

Бронников Андрей Михайлович – д-р техн. наук, МГТУ
им. Н.Э. Баумана, ✉ bronnikov_a_m@mail.ru,
ORCID iD: <https://orcid.org/0009-0009-1216-3521>

Попов Александр Сергеевич – канд. техн. наук, ВУНЦ ВВС
«Военно-воздушная академия им. проф. Н. Е. Жуковского и
Ю. А. Гагарина», г. Воронеж, ✉ saga30@yandex.ru,

Шурман Владимир Александрович – АО «НИИ авиацион-
ного оборудования», г. Жуковский, ✉ shurman@niiao.ru

© 2025 г. Буков В. Н., Бронников А. М., Попов А. С.,
Шурман В. А.



Эта статья доступна по лицензии Creative Commons
«Attribution» («Атрибуция») 4.0 Всемирная.

TECHNICAL CONDITION MONITORING METHODS TO MANAGE THE REDUNDANCY OF SYSTEMS.

PART III: Nonclassical Models in Fault Diagnosis

V. N. Bukov*, A. M. Bronnikov**, A. S. Popov***, and V. A. Shurman****

*Airborne Aeronautical Systems, Moscow, Russia

**Bauman Moscow State Technical University, Moscow, Russia

***Zhukovsky–Gagarin Air Force Academy, Voronezh, Russia

****Institute of Aircraft Equipment, Zhukovsky, Russia

*✉ v_bukov@mail.ru, **✉ bronnikov_a_m@mail.ru, ***✉ saga30@yandex.ru, ****✉ shurman@niiao.ru

Abstract. Redundancy management in a technical system involves a monitoring procedure to reconfigure the system as needed. The four-part survey presents modern diagnosis methods for dynamic systems as an integral function of monitoring. Part III is devoted to diagnosis methods employing neural networks, fuzzy models, structural models, set-based models, and a statistical approach. The fundamentals of creating and training neural networks to perform diagnostic functions are considered. The approach with fuzzy models is described, including general modeling rules and the features of their use in diagnosis tasks. The approach with structural models is demonstrated, including its features in failure detection. The fundamentals of set-theory methods, particularly the formalism of zonotopes, are presented. Finally, the approach based on statistical pattern recognition is briefly discussed.

Keywords: artificial neuron, neural network, fuzzy models, membership function, fuzzy clustering, structural models, Dulmage–Mendelsohn decomposition, diagnosability, zonotopes, gradations in discrete feature space, empirical likelihood ratio estimate.