

Система обработки данных для диагностирования системы управления газотурбинным двигателем

А. М. Синица, М. Ю. Шестопалов, Д. Х. Имаев✉

Санкт-Петербургский государственный электротехнический университет «ЛЭТИ» им. В. И. Ульянова (Ленина), Санкт-Петербург, Россия

✉ damir.imaev@mail.ru

Аннотация. Рассматривается система обработки данных, предназначенная для диагностирования системы управления газотурбинным двигателем. Реализована процедура последовательного формирования диагностических признаков, выявления симптомов неисправностей и постановки диагноза. Предложено последовательно усложнять структуру нейросетевой системы обработки данных с целью достижения требуемого качества классификации технического состояния диагностируемого объекта. Приводится пример диагностирования предложенной У. Роуэном модели системы управления газовой турбиной.

Ключевые слова: диагностирование, система обработки данных, нейронная сеть, газотурбинный двигатель, система управления

Для цитирования: Синица А. М., Шестопалов М. Ю., Имаев Д. Х. Система обработки данных для диагностирования системы управления газотурбинным двигателем // Изв. СПбГЭТУ «ЛЭТИ». 2022. Т. 15, № 2. С. 32–40. doi: 10.32603/2071-8985-2022-15-2-32-40.

Original article

Data processing for the gas turbine control system diagnostics

A. M. Sinitca, M. Yu. Shestopalov, D. H. Imaev✉

Saint Petersburg Electrotechnical University, Saint Petersburg, Russia

✉ damir.imaev@mail.ru

Abstract. A system for processing diagnostic data of a gas turbine control system is considered. The procedures for obtaining diagnostic signs, identifying the symptoms of faults, and diagnosing the technical state of the control system have been implemented. It is proposed to sequentially complicate the structure of the neural network data processing system to achieve the required quality of classification of the diagnosed object technical state. An example of diagnostics of a model of a gas turbine control system proposed by W. Rowen is given.

Keywords: diagnostics, data processing system, neural network, gas turbine, control system

For citation: Sinitca A. M., Shestopalov M. Yu., Imaev D. H. Data processing for the gas turbine control system diagnostics // LETI Transactions on Electrical Engineering & Computer Science. 2022. Vol. 15, no. 2. P. 32–56. doi: 10.32603/2071-8985-2022-15-2-32-56.

Введение. Современные системы управления (СУ) техническими объектами и технологическими процессами образованы многими компонентами — датчиками, контроллерами, исполнительными органами и каналами передачи данных. С повышением сложности систем множится число потенциальных неисправностей — маловероятных событий, которые не предусмотрены на этапе

проектирования, но могут привести к отказам оборудования с серьезными последствиями.

Фундаментальные и прикладные вопросы диагностирования СУ рассмотрены в работах С. В. Раммурфи [1], А. В. Мозгалева [2], Р. Исерманна [3], А. С. Кулика [4], М. М. Поликарпоу, А. Т. Вемури, Р. М. Франка [5]–[7], П. В. Глущенко [8] и др. Обзору публикаций по диагно-

стике СУ техническими объектами посвящены [3], [9]. Интерес к диагностированию технического состояния СУ возрос в связи с интенсивными разработками проблемы отказоустойчивости управления. В отказоустойчивых, или толерантных к неисправностям, СУ (англ. Fault-Tolerant Control Systems – FTCS) поддерживается временная работоспособность неисправной системы, не допускающая развития ситуации до отказов и аварий [10]–[13].

Диагностирование сводится к нетривиальным процедурам обработки данных, доставляемых датчиками. Если процедуры диагностирования не удастся полностью алгоритмизировать, то задачи диагностирования могут решаться методами машинного обучения, например в виде Neuro-Fuzzy-систем [13]–[17].

В силу многообразия постановок задач диагностирования не удастся разработать универсальную систему обработки данных (СОД). Вместе с тем, процедуры обработки данных в задачах диагностирования СУ техническими и технологическими объектами в различных отраслях промышленности имеют общие черты. Целесообразно развивать модели, методы и алгоритмы разработки специализированных СОД в задачах диагностирования систем автоматического управления.

В статье предложена СОД диагностирования функционального состояния СУ, основанная на искусственных нейронных сетях двух типов. Рассматривается пример диагностирования СУ газотурбинным двигателем (ГТД).

Последовательность обработки данных диагностирования. Цель диагностирования заключается в обнаружении, локализации и идентификации неисправностей. Источниками информации о техническом и функциональном состоянии СУ служат данные о переменных состояния объекта управления, управляющих и возмущающих воздействиях, а также данные о сигналах входов/выходов различных преобразователей и фильтров. Обработка данных вскрывает содер-

жащуюся в них информацию, а правильная интерпретация информации формирует знание об искомых неисправностях или их отсутствии.

Рассматриваются неисправности двух типов – «жесткие» и «мягкие». «Жесткие» неисправности, вызванные стремительно развивающимися повреждениями, моделируются как скачкообразные изменения параметра. «Мягкие» неисправности, связанные с постепенной деградацией системы, описываются как непрерывные изменения параметра во времени. Объект диагностируется как неисправный, если диагностические признаки достигают установленных порогов.

В случае жесткой неисправности выделяется конечное множество систем с различными параметрами, среди которых одна система исправна, а другие – нет. Задача распознавания мягких неисправностей оказывается более сложной, так как исправные и неисправные состояния объекта диагностирования образуют континуум. Для обучения классификаторов выявления симптомов необходимо предварительно составить репрезентативные выборки исправных и неисправных систем.

Обнаружение и локализация неисправностей СУ связаны с нетривиальными процедурами обработки данных измерений для формирования диагностических признаков (ДП), выявления симптомов неисправностей и постановки диагноза о техническом состоянии. Представленная на рис. 1 последовательность обработки данных отражает декомпозицию процедуры диагностирования СУ [13]. Обработка данных измерений $y_q[k]$; $k = 1, 2, \dots$ формирует ДП $d_i[K]$; $K = 1, 2, \dots$, которые подаются на входы нейронных классификаторов NN_i , обученных выявлять симптомы неисправностей.

В [13] введено понятие ДП различных категорий (рис. 2). ДП нулевой категории $d_0[k]$ представляют мгновенные значения $y_q(t)$ или числовые последовательности $y_q[k] \equiv y_q(t = kT_s)$, где




Рис. 1. Последовательность обработки данных

Fig. 1. Data processing sequence

T_s – период дискретизации времени. Уровни управляемых переменных и управляющих воздействий СУ, а также их соотношение всегда контролируются, и нарушение ими допустимых границ свидетельствует о неисправностях. ДП $d_0[k]$ обеспечивают примитивный уровень диагностирования, достоинство которого заключается в скорости обнаружения неисправностей. Возможности диагностирования СУ техническими объектами по экспертным правилам, основанным на пороговых значениях переменных, ограничены.




Рис. 2. Диагностические признаки различных категорий

Fig. 2. Diagnostic signs of various categories

За ДП первой категории $d_1[k]$ принимаются выборки $\{y_q[k]; k = 1, 2, \dots, K\}$, которые накапливаются в буфере Buffer. Поскольку непосредственный перенос экспертных знаний к выборкам затруднителен, используют ДП второй категории $d_2[k]$ – результаты статистической обработки выборок данных: средние, дисперсии с выборки, спектрального или корреляционного анализа, коэффициенты идентифицированной параметрической модели типа AR и т. п. К ДП третьей категории $d_3[k]$ в случае диагностирования СУ относят показатели качества процессов, например модули собственных значений (СЗ) матриц состояний, параметры их локализации и другие косвенные показатели качества процессов.

Выявление симптома $c_j[K]$ означает обнаружение неисправности. В частном случае единственный симптом означает и диагноз технического состояния $D[K]$. Как правило, диагноз ставится по совокупности симптомов $\{c_j; j = 1, 2, \dots\}$. В общем случае переменная выхода i -го компонента СУ влияет на несколько измеряемых выходов $y_q[k]$ системы (см. рис. 1), а неисправности различных компонентов изменяют характеристики сигнала одного и того же выхода. Это приводит к интерференции симптомов, выявляемых классификаторами, настроенными на конкретные неисправ-

ности. Постановка диагноза по перекрывающимся симптомам представляет неполные формализуемую задачу значительной сложности, которая не решается традиционными методами.

Система обработки данных. Диагностирование рассматривается как отнесение технического состояния объекта к определенному классу в пространстве ДП. Задача диагностирования носит информационный характер и может решаться методами, инвариантными к природе объекта. В частности, рассматриваемая задача сводится к классификации временных рядов, т. е. системы диагностирования относятся к семейству систем обработки данных (СОД).

Предлагается синтезировать СОД в виде нейронной сети двухуровневой архитектуры [17]. Первый уровень состоит из N обучающихся независимо друг от друга подсетей, которые выявляют симптомы той или иной неисправности. Подсети можно интерпретировать как атомарные модули обработки данных (МОД). Использование множества атомарных МОД способно гибко менять СОД с целью повышения качества диагностирования, адаптировать ее к изменившимся условиям или к смежной задаче.

Обученные независимо нейронные сети могут иметь пересечения классов неисправностей, формируя ложноположительную принадлежность к своему классу при данных на входе, соответствующих неизвестному классу состояния объекта. Несмотря на этот недостаток, обучение нейронной сети на двух классах значительно проще, что позволяет использовать относительно небольшие сети прямого распространения (FF-сети). Для компенсации эффекта интерференции классов неисправностей вводится второй уровень нейронной сети, входами которой оказываются выходы $2N$ подсетей первого уровня.

Примем эволюционный подход к синтезу СОД, который заключается в постепенном усложнении структуры СОД и образующих ее компонентов. На первом этапе для всех компонентов используются FF-сети, хорошо зарекомендовавшие себя для задач бинарной классификации. Далее структура системы усложняется – для выделения ДП используются более сложные рекуррентные LSTM-сети [18], способные анализировать последовательности данных различной природы.

На рис. 3 представлены структуры нейросетевых моделей диагностирования с сетью прямого распространения (FF-сеть) для выявления симптомов (рис. 3, а) и LSTM-сетью (рис. 3, б) – для постановки диагноза. Заметим, что в отличие от




Рис. 3. Структуры нейросетевых моделей диагностирования: а – с сетью прямого распространения; б – LSTM-сетью
 Fig. 3. Structures of neural network models for diagnosing: а – with a feed-forward network; б – with an LSTM network

сети прямого распространения, где вход – отрезок временной последовательности, на входе рекуррентной LSTM-сети – мгновенные значения наблюдаемых параметров.

Пример диагностирования СУ ГТД. В качестве примера объекта диагностирования используется предложенная У. Роуэном модель СУ газовой турбины фирмы General Electric типа GE 7001B [19], [20]. Для получения так называемой диагностической модели [13] компьютерная модель на языке графического редактора MatLab/Simulink дополнена моделями потенциальных неисправностей, а к измеряемым выходам подключены датчики (рис. 4).

Правая часть модели СУ ГТД представляет модель собственно турбины: наверху – блоки, описывающие изменения температуры выхлопных газов и измерения температуры; по центру схемы – топливная подсистема, включающая в себя топливный клапан, компрессор и камеру сгорания; в нижней части схемы представлены уравнения связи крутящего момента, частоты вращения ротора, момента нагрузки и расхода сжигаемого топлива. Левая часть модели содержит контроллер, состоящий из трех компонентов: управления частотой вращения, температурой и ускорением. Последние два компонента предотвращают перегрев или чрезмерные ускорения турбины. Переменные (за исключением температуры) нормированы относительно номинальных значений.

Учитываются группы неисправностей, связанные с подсистемой подачи топлива и датчиком температуры (термопарой). На рис. 4 выделены блоки, имитирующие неисправности СУ газовой турбины:

- 1 – жесткая мультипликативная неисправность топливной системы (блок [fuelFault]);
- 2 – мягкая мультипликативная неисправность топливной системы (блок [fuelFault]);
- 3 – жесткая мультипликативная неисправность датчика температуры (блок [thermoFault_mult]);
- 4 – мягкая мультипликативная неисправность датчика температуры (блок [thermoFault_mult]);

5 – жесткая аддитивная неисправность датчика температуры (блок [thermoFault_add]);

6 – мягкая аддитивная неисправность датчика температуры (блок [thermoFault_add]).

Сформулируем следующие требования к СОД:

- система должна выявлять 7 состояний объекта: одно исправное и 6 неисправностей;
- размерность данных входа СОД: 4 сигнала по 100 отсчетов;
- показатель качества СОД – средняя точность классификации.

Нейросетевая СОД диагностирования обучается в два этапа: на первом этапе обучаются нейронные сети первого уровня и фиксируются значения их весов. На втором этапе подстраиваются веса сети второго уровня.

Подготовка данных для обучения нейронных сетей. В качестве примера генерирования обучающих данных выбрана Simulink-модель СУ газовой турбины (рис. 4). Пусть одновременно может случиться только одна из шести неисправностей СУ. Кроме того, время наступления и интенсивность неисправности принимаются случайными величинами, различными для каждой итерации моделирования. Принято, что интенсивность мультипликативных неисправностей (значения множителей) принадлежат диапазону [0...0.1], аддитивных неисправностей – диапазону [0...0.01]. Таким образом, рассматриваются только те неисправности, которые не приводят к отказам в краткосрочной перспективе и могут достаточно долго оставаться незамеченными.

Разработаны специальные подпрограммы, позволяющие автоматизировать процесс подготовки обучающих последовательностей. М-файл подготовки отрезков временных рядов имеет следующие параметры:

- значение ошибки – нормированное значение от 0 до 1, определяющее максимальное значение параметра, описывающего неисправность;
- тип ошибки – значение от 0 до 6, где 0 означает моделирование исправной системы, остальные




Рис. 4. Компьютерная модель на языке графического редактора MatLab/Simulink
Fig. 4. Computer model in the language of the graphic editor MatLab/Simulink


значения – моделирование системы с присутствием неисправности согласно списку из раздела 2;

– время ошибки – время возникновения неисправности (для мягких неисправностей соответствует времени начала изменения коэффициента).

Данные компьютерной имитации разделены на блоки по 100 отсчетов, соответствующие группе входов из 100 элементов в случае FF-сетей прямого распространения и 100 тактам работы сети при использовании рекуррентной нейронной LSTM-сети. Для каждого типа неисправности, а также для исправного состояния сгенерировано 300 последовательностей длительностью 600 модельных секунд со случайным моментом наступления ошибки и наличием шума. Из этих последовательностей вырезаны отрезки требуемой длины.

Обучение нейронной сети. Обучение производится в $N + 1$ этап, где N – число потенциальных неисправностей. В первую очередь обучаются нейронные сети, предназначенные для выявления принадлежности состояния объекта к одному из классов неисправности. Это позволяет добиться большей точности классификации на первом уровне классификатора, что почти полностью исключает ложные срабатывания системы диагностирования.

Анализ нейросетевой модели СОД основан на сравнении качества диагностирования каждой из рассматриваемых архитектур СОД, обучаемых на выборках одинакового размера. Критериями качества служат точность диагностирования и доля ложноположительных срабатываний.



1. В результате ручного поиска архитектуры формирователя ДП принята трехслойная полно-связная FF-сеть (прямого распространения) с 400 нейронами в каждом слое. Выходной слой сети имеет 2 нейрона (наличие или отсутствие неисправности). Нейронная сеть второго уровня (постановка диагноза) состоит из двух слоев по 80 нейронов и выходного слоя с 7 нейронами (по числу состояний СУ).

Для визуализации результатов обучения использована так называемая матрица спутанности (англ. confusion matrix), строки которой обозначают истинный индекс класса, а столбцы – индекс, предсказанный моделью (рис. 5). В клетке i, j матрицы находится число элементов типа j , классифицированных моделью как класс i . Таким образом, идеальная модель системы классификации должна иметь диагональную матрицу спутанности.

По итогам обучения нейронной сети прямого распространения при распознавании 6 типов неисправностей СУ газовой турбиной получена точность 64 % с матрицей спутанности (рис. 5, а) для СОД, использующей FF-сети для выявления ДП. Матрица показывает наличие неисправности 1 («жесткая мультипликативная неисправность топливной системы»). Наблюдается значительное количество ложноположительных срабатываний с диагнозом 6 – «мягкая аддитивная неисправность термопары» при исправном СУ, что, вероятно, связано с характером проявления неисправности. Также имеется значительное число ложноотрицательных срабатываний (с учетом объединения исправного состояния и неисправности 1).




Рис. 5. Визуализация матриц спутанности для: а – СОД с использованием FF-сети для извлечения признаков; б – СОД с использованием LSTM-сети для извлечения признаков

Fig. 5. Visualization of confusion matrices for: а – Data processing system using FF network for feature extraction; б – Data processing system using LSTM network for feature extraction

Отметим, что при использовании сетей прямого распространения эквивалентного размера для непосредственного диагностирования всех рассматриваемых состояний СУ турбиной достигнута точность менее 17 %.

Качество диагностирования FF-сетей, достигнутое поиском максимальной с использованием параметрической реконфигурации модели обработки данных, неприемлемо, так как вероятность корректного диагноза сопоставима со случайным выбором.

2. Изменим структуру подсистемы формирования ДП – применим рекуррентные нейронные сети LSTM. Архитектура LSTM-сети выделения диагностического признака состоит из 3 слоев, включающих в себя по 100 LSTM-блоков. Архитектура сети второго уровня остается без изменений.

При обучении рекуррентной нейронной сети заметны преимущества на первом этапе диагностирования – обученная сеть менее чувствительна к выбору начальных параметров, а также обеспечивается большая точность постановки диагноза. Точность диагностирования при использовании в качестве бинарного классификатора LSTM-сети составила 67 % (рис. 5, б). Кроме того, при проверке эффективности LSTM-сети при одноуровневой архитектуре нейросетевого аппарата диагностирования получена точность около 65 %.

Стоит отметить, что несмотря на повышение используемого интегрального показателя качества, более сложная структура модели СОД не в состоянии выделить состояние мягкой аддитивной ошибки температурного датчика. Это говорит о целесообразности дальнейшего усложнения модели СОД, например с помощью ансамблирования нейросетевых моделей разных типов.

Процессы создания, обучения и тестирования нейронной сети в TensorFlow [22] на языке Python автоматизированы и с минимальными изменениями могут применяться и в других задачах машинного обучения.

Заключение. Предложена процедура разработки двухуровневых диагностических систем с бинарными нейросетевыми классификаторами на первом уровне и итоговым классификатором – на втором. Анализируется эффективность использования нейронных FF-сетей прямого распространения в моделях первого уровня и рекуррентных LSTM-сетей.

Показано, что искусственные нейронные сети, хорошо зарекомендовавшие себя в задачах бинарной классификации, менее эффективны в задачах диагностирования, как правило, связанных с многоальтернативной классификацией ситуаций. Предложена система диагностирования на базе многоуровневой архитектуры с предварительным обучением компонентов на подзадачах выявления симптомов. Результаты компьютерных экспериментов показывают рост эффективности модели диагностирования, синтезированной предложенным методом, и сходимости процесса обучения сетей прямого распространения. Вместе с тем, такой метод не способен значительно повысить качество диагностирования по сравнению с одноуровневыми моделями на основе LSTM-сетей.

Время обучения рекуррентных нейронных сетей значительно превосходит время обучения сетей прямого распространения. При использовании двухуровневой архитектуры качество диагностирования для рекуррентной сети и сети прямого распространения сопоставимо, что позволяет говорить о целесообразности дальнейших исследований по анализу декомпозированных архитектур устройств диагностирования.

Использование только «сырых» данных в виде отрезков временных рядов ограничивает качество диагностирования. Необходимо добавление этапа формирования диагностических признаков высших категорий – предобработка исходных данных для получения частотных, кепстральных и статистических представлений. Последовательное усложнение системы обработки данных может быть продолжено с целью повышения достигнутых показателей качества.

Процедура синтеза системы обработки данных, скомбинированных из разных типов нейронных сетей, апробирована на задаче диагностирования неисправностей компьютерной модели системы управления газовой турбиной. Можно предположить, что развитие идеи последовательного усложнения структур систем обработки данных, построенной на множестве неделимых алгоритмов вычислений («атомов»), может быть обобщена на задачи синтеза систем обработки данных диагностирования технического состояния и других объектов, причем не только технических.

Список литературы

1. Ramamoorthy C. V. A structural theory of machine diagnosis / Proc. of Spring Joint Computers Conference. 1967. No. 30. P. 743–756.

2. Мозгалеvский А. В. Техническая диагностика (непрерывные объекты). Обзор // Автоматика и телемеханика, 1978. № 1. С. 145–166.

3. Isermann R. Process fault detection based on modelling and estimation methods – a survey // *Automatica*. 1984. Vol. 20, no. 4. P. 387–404.
4. Кулик А. С. Диагностируемость линейных непрерывных систем // *Автоматика и телемеханика*. 1987. № 6. С. 148–155.
5. Frank P. M. Fault diagnosis in dynamic systems using analytical and knowledge-based redundancy – a survey and some new results // *Automatica*. 1990. Vol. 26, no. 3. P. 459–474.
6. Polycarpou M. M., Vemuri A. T. Learning methodology for failure detection and accommodation // *IEEE Control System Magazine*. 1995. Vol. 15. P. 16–24.
7. Patton R., Frank P., Clark R. Issues of fault diagnosis for dynamic systems. London: Springer-Verlag, 2000. 565 p.
8. Глуценко П. В. Техническая диагностика. М.: Вузовская книга, 2004. 248 с.
9. Zhang Y., Jiang J. Bibliographical review on reconfigurable fault-tolerant control systems // *Annual Reviews in Control*. 2008. Vol. 32. P. 229–252.
10. Алгоритмическое обеспечение отказоустойчивости систем автоматического управления / В. М. Глумов, С. Д. Земляков, В. Ю. Рутковский, А. В. Силаев // *Автоматика и телемеханика*. 1988. № 9. С. 3–33.
11. Diagnosis and fault tolerant control. Control Systems. Vol. 2 / M. Blanke, M. Kinnaert, J. Lunze, M. Staroswiecki. Springer-Verlag, London, 2006. P. 227.
12. Zhou D. H., Frank P. M. Fault diagnosis and fault tolerant control // *IEEE Trans. Aerospace and Electronic Systems*. 1998. No. 34 (2). P. 420–427.
13. Шестопапов М. Ю. Системы отказоустойчивого управления технологическими процессами. СПб.: Элмор, 2013. 308 с.
14. Ayoubi M., Isermann R. Neuro-Fuzzy systems for diagnosis // *Fuzzy Sets and Systems*. 1997. No. 89, P. 289–307.
15. Korbicz J., Kościelny J. (red) i inni. Diagnostyka procesow. Modele. Metody sztucznej inteligencji. Zastosowania. Warszawa: WNT, 2002. 828 p.
16. Нейросетевое диагностирование системы управления турбоагрегатом / Е. В. Гузаев, Ю. А. Кораблев, М. Ю. Шестопапов, Д. Х. Имаев // *Изв. СПбГЭТУ «ЛЭТИ»*. 2018. № 1. С. 44–48.
17. Кребс В., Кораблев Ю., Шестопапов М. Диагностика на основе нейро-нечетких технологий в системах технического управления // *Международ. конф. по мягким вычислениям и измерениям*. СПб.: Изд-во СПбГЭТУ «ЛЭТИ», 2004. Т. 2. С. 208–210.
18. Разработка нейросетевых моделей диагностирования систем управления турбоагрегатом / Д. Х. Имаев, А. М. Синица, М. Ю. Шестопапов, С. В. Квашнин // *IEEE Northwest Russia Conf. On Mathematical Methods In Engineering And Technology: MMET NW 2018*. СПб.: Изд-во СПбГЭТУ «ЛЭТИ». 2018. С. 62–65.
19. Rowen W. I. Simplified mathematical representations of heavy-duty gas turbines // *ASME J. Eng. Power*. 1983. Vol. 105. P. 865–869.
20. Yee S. K., Milanovic J. V., Hughes F. M. Overview and comparative analysis of gas turbine models for system stability studies // *IEEE Trans. Power Syst*. 2008. Vol. 23, no. 1. P. 108–118.
21. Hochreiter S., Schmidhuber J. Long short-term memory // *Neural Computation*. 1997. Vol. 9, no. 8. P. 1735–1780.
22. TensorFlow: a system for large-scale machine learning / M. Abadi, P. Barham, J. Chen, Z. Chen, A. Davis, J. Dean, M. Devin, S. Ghemawat, G. Irving, M. Isard, M. Kudlur, J. Levenberg, R. Monga, S. Moore, D. G. Murray, B. Steiner, P. Tucker, V. Vasudevan, P. Warden, X. Zheng // *Proc. of the 12th USENIX conf. on Operating Systems Design and Implementation*. USA: USENIX Association, 2016. P. 265–283.

Информация об авторах

Синица Александр Михайлович – ассистент кафедры автоматике и процессов управления, факультет компьютерных технологий и информатики СПбГЭТУ «ЛЭТИ».

E-mail: amsinitca@etu.ru

<https://orcid.org/0000-0001-9869-4909>

Шестопапов Михаил Юрьевич – д-р техн. наук, доцент, заведующий кафедрой автоматике и процессов управления, факультет компьютерных технологий и информатики СПбГЭТУ «ЛЭТИ».

E-mail: shestopalov_08@mail.ru

Имаев Дамир Хабибович – д-р техн. наук, профессор кафедры автоматике и процессов управления, факультет компьютерных технологий и информатики СПбГЭТУ «ЛЭТИ».

E-mail: damir.imaev@mail.ru

References

1. Ramamoorthy C. V. A structural theory of machine diagnosis / *Proc. of Spring Joint Computers Conf.* 1967. No. 30. P. 743–756.
2. Mozgalevskij A. V. Tekhnicheskaya diagnostika (ne-preryvnye ob'ekty). Obzor / *Avtomatika i telemechanika*, 1978. No. 1. S. 145–166. (In Russ.).

3. Isermann R. Process fault detection based on modelling and estimation methods – a survey // *Automatica*. 1984. Vol. 20, no. 4. P. 387–404. (In Russ.).
4. Kulik A. C. Diagnostiruemost' linejnyh nepreryvnyh sistem // *Avtomatika i telemekhanika*. 1987. No. 6. S. 148–155. (In Russ.).
5. Frank P. M. Fault diagnosis in dynamic systems using analytical and knowledge-based redundancy – a survey and some new results // *Automatica*. 1990. Vol. 26, no. 3. P. 459–474.
6. Polycarpou M. M., Vemuri A. T. Learning methodology for failure detection and accommodation // *IEEE Control System Magazine*. 1995. Vol. 15. P. 16–24.
7. Patton R., Frank P., Clark R. *Issues of Fault Diagnosis for Dynamic Systems*. London: Springer-Verlag, 2000. 565 p.
8. Glushchenko P. V. *Tekhnicheskaya diagnostika*. M.: Vuzovskaya kniga, 2004. 248 s. (In Russ.).
9. Zhang Y., Jiang J. Bibliographical review on reconfigurable fault-tolerant control systems // *Annual Reviews in Control*. 2008. Vol. 32. P. 229–252.
10. Glumov V. M., Zemlyakov S. D., Rutkovskij V. YU., Silaev A. V. Algoritmicheskoe obespechenie otkazoustojchivosti sistem avtomaticheskogo upravleniya // *Avtomatika i telemekhanika*. 1988. № 9. S. 3–33. (In Russ.).
11. Blanke M., Kinnaert M., Lunze J., Staroswiecki M. *Diagnosis and Fault Tolerant Control*. Control Systems, Vol. 2. Springer-Verlag, London, 2006. P. 227.
12. Zhou D. H., Frank P. M. Fault diagnosis and fault tolerant control // *IEEE Trans. Aerospace and Electronic Systems*. 1998. No. 34 (2). P. 420–427.
13. Shestopalov M. YU. *Sistemy otkazoustojchivogo upravleniya tekhnologicheskimi processami*. SPb.: Elmor, 2013. 308 s. (In Russ.).
14. Ayoubi M., Isermann R. Neuro-fuzzy systems for diagnosis // *Fuzzy Sets and Systems*. 1997. No. 89. P. 289–307.
15. Korbicz J., Kościelny J. (red) i inni. *Diagnostyka procesow. Modele. Metody sztucznej inteligencji. Zastosowania*. Warszawa: WNT, 2002. 828 p. (In Russ.).
16. Nejrosetevoe diagnostirovanie sistemy upravleniya turboagregatom / E. V. Guzaev, YU. A. Korablev, M. YU. Shestopalov, D. H. Imaev // *Izd-vo SPbGETU «LETI»*. 2018. № 1. S. 44–48. (In Russ.).
17. Razrabotka nejrosetevykh modelej diagnostirovaniya sistem upravleniya turboagregatom / D. H. Imaev, A. M. Sinica, M. YU. Shestopalov, S. V. Kvashnin // *IEEE Northwest Russia Conf. On Mathematical Methods In Engineering And Technology: MMET NW 2018*. SPb.: Izd-vo SPbGETU «LETI», 2018. S. 62–65. (In Russ.).
18. Rowen W. I. Simplified mathematical representations of heavy-duty gas turbines // *ASME J. Eng. Power*. 1983. Vol. 105. P. 865–869.
19. Yee S. K., Milanovic J. V., Hughes F. M. Overview and Comparative Analysis of Gas Turbine Models for System Stability Studies // *IEEE Trans. Power Syst.* 2008. Vol. 23, no. 1. P. 108–118.
20. Hochreiter S., Schmidhuber J. Long Short-Term Memory // *Neural Computation*. 1997. Vol. 9, no. 8. P. 1735–1780.
22. Abadi M., Barham P., Chen J., Chen Z., Davis A., Dean J., Devin M., Ghemawat S., Irving G., Isard M., Kudlur M., Levenberg J., Monga R., Moore S., Murray D. G., Steiner B., Tucker P., Vasudevan V., Warden P., Zheng X. *TensorFlow: a system for large-scale machine learning* // *Proc. of the 12th USENIX conf. on Operating Systems Design and Implementation*. USA: USENIX Association, 2016. P. 265–283.

Information about the authors

Aleksandr M. Sinitca – Associate Professor of Saint Petersburg Electrotechnical University.

E-mail: amsinitca@etu.ru

<https://orcid.org/0000-0001-9869-4909>

Mikhail Yu. Shestopalov – Dr of Sci. (Eng.), Associate Professor of Saint Petersburg Electrotechnical University.

E-mail: shestopalov_08@mail.ru

Damir H. Imaev – Dr of Sci. (Eng.), Professor of Saint Petersburg Electrotechnical University.

E-mail: damir.imaev@mail.ru

Статья поступила в редакцию 11.01.2022; принята к публикации после рецензирования 07.02.2022; опубликована онлайн 11.03.2022.

Submitted 11.01.2022; accepted 07.02.2022; published online 11.03.2022.
