



Научная статья

УДК 681.518

URL: <https://trudymai.ru/published.php?ID=188109>

EDN: <https://www.elibrary.ru/QOOYPC>

**СИСТЕМА ВСТРОЕННОГО ТЕХНИЧЕСКОГО ДИАГНОСТИРОВАНИЯ,  
РЕЗЕРВИРОВАНИЯ И ПРОГНОЗИРОВАНИЯ ТЕХНИЧЕСКОГО СОСТОЯНИЯ  
БОРТОВОГО ОБОРУДОВАНИЯ ВОЗДУШНЫХ СУДОВ НА ОСНОВЕ МЕТОДОВ  
МАШИННОГО ОБУЧЕНИЯ**

**Андрей Дмитриевич Савчук, Андрей Юрьевич Савченко, Семен Анатольевич  
Миронов, Александр Сергеевич Букирёв**✉

Военный учебно-научный центр Военно-воздушных Сил «Военно-Воздушная  
Академия имени профессора Н.Е. Жуковского и Ю.А. Гагарина», г. Воронеж, Россия

✉ [bukirev@inbox.ru](mailto:bukirev@inbox.ru)

---

**Цитирование:** Савчук А.Д., Савченко А.Ю., Миронов С.А., Букирёв А.С. Система встроенного технического диагностирования, резервирования и прогнозирования технического состояния бортового оборудования воздушных судов на основе методов машинного обучения // Труды МАИ: электрон. журнал. № 147. URL: <https://trudymai.ru/published.php?ID=188109>

---

**Аннотация.** Обоснована необходимость повышения глубины локализации отказов бортового оборудования воздушных судов с применением методов машинного обучения. Разработана система встроенного технического диагностирования, резервирования и прогнозирования технического состояния, основанная на взаимодействии с мультиплексным каналом информационного обмена. Ключевые особенности системы включают: алгоритм автоматического определения параметров обучения для каждого контролируемого элемента на этапе диагностики; использование рекуррентной нейронной сети с долгой краткосрочной памятью для прогнозирования состояния; механизм динамического резервирования отказавших элементов.

**Ключевые слова:** бортовое оборудование, машинное обучение, ансамблирование, диагностирование, резервирование, прогнозирование, техническое состояние.

---

## **A SYSTEM OF INTEGRATED TECHNICAL DIAGNOSTICS, REDUNDANCY AND FORECASTING OF THE TECHNICAL CONDITION OF AIRCRAFT ON-BOARD EQUIPMENT BASED ON MACHINE LEARNING METHODS**

**A.D. Savchuk, A.Y. Savchenko, S.A. Mironov, A.S. Bukirev**<sup>✉</sup>

MESC Air Force «Air Force Academy named after professor N.E. Zhukovskii and Yu.A. Gagarin», Voronezh, Russia

<sup>✉</sup>[bukirev@inbox.ru](mailto:bukirev@inbox.ru)

---

**Citation:** Savchuk A.D., Savchenko A.Yu., Mironov S.A., Bukirev A.S. A system of integrated technical diagnostics, redundancy and forecasting of the technical condition of aircraft on-board equipment based on machine learning methods // Trudy MAI. 2026. No. 147. (In Russ.) URL: <https://trudymai.ru/published.php?ID=188109>

---

**Abstract.** The necessity of increasing the depth of localization of failures of on-board equipment of aircraft using machine learning methods is substantiated. A system of integrated technical diagnostics, redundancy and forecasting of technical condition based on interaction with a multiplex channel of information exchange has been developed. Key features of the system include: an algorithm for automatically determining learning parameters for each monitored element at the diagnostic stage; using a recurrent neural network with long-term short-term memory to predict the state; a mechanism for dynamic redundancy of failed elements.

**Keywords:** on-board equipment, machine learning, diagnostics, redundancy, forecasting, technical condition.

---

### **Введение**

Современный этап развития авиационной техники характеризуется активным внедрением информационных технологий в бортовое оборудование, в

частности, в виде информационно-преобразующих элементов. Высокая интенсивность работы авиационных частей обуславливает возрастание количества отказов таких элементов, что приводит к увеличению простоя и снижению коэффициента технической готовности воздушного судна (ВС). Глубина поиска места отказа современными бортовыми автоматизированными системами контроля (БАСК) составляет уровень конструктивно-съемных единиц не для всех информационно-преобразующих элементов (ИПЭ), так как используемые диагностические модели подразумевают применение метода логических функций для их создания [1-2]. Бортовое оборудование (БО), не имеющее встроенную систему контроля, проверяется в режиме контроля исправности соответствующих линий связи между устройствами, а также в режиме проверки правильности структуры передаваемого кода [3]. Это препятствует повышению глубины поиска для элементов с трудноформализуемыми моделями. Таким образом, необходимо увеличить глубину поиска места отказа в БО до уровня конструктивно-съемного ИПЭ.

Анализ результатов исследований в рассматриваемой предметной области показал, что предложенные алгоритмы и методики определения технического состояния основаны на применении систем искусственного интеллекта: методов машинного обучения, искусственных нейронных сетей и нечеткой логики. Однако в рассмотренных работах имеются нерешенные задачи, связанные с автоматизацией формирования обучающих выборок, определением параметров обучения алгоритмов и учетом влияния внешних возмущающих воздействий [4-8].

Разработана функциональная модель технического диагностирования, резервирования и прогнозирования технического состояния информационно-преобразующих элементов БО ВС на основе методов машинного обучения. Данная модель представляет собой блок-схему последовательного процесса взаимодействия разработанного модуля через магистральную шину мультиплексного канала информационного обмена [9] (рисунок 1).

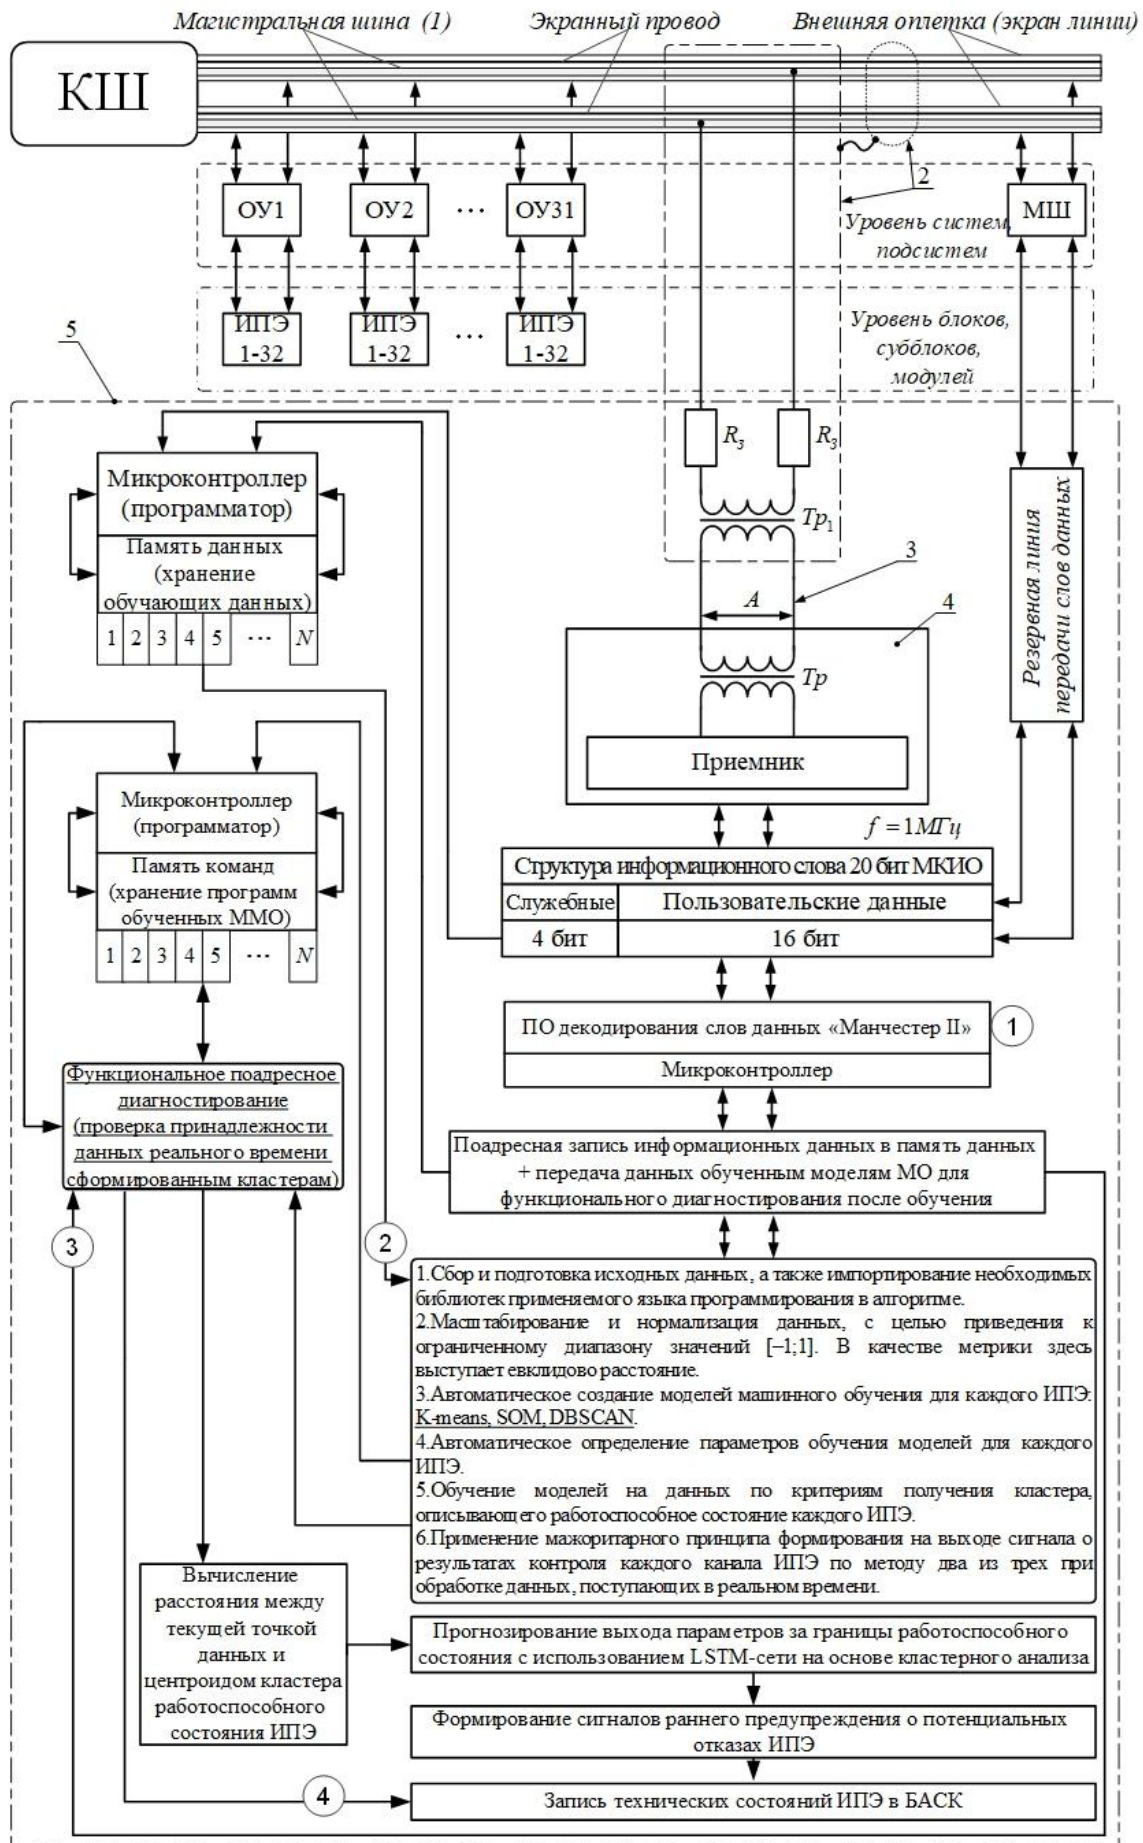


Рисунок 1 – Функциональная модель технического диагностирования, резервирования и прогнозирования технического состояния информационно-преобразующих элементов бортового оборудования воздушного судна на основе методов машинного обучения

С целью автоматического формирования диагностических моделей любой сложности наиболее подходящим инструментом машинного обучения является кластеризация. Кластеризация позволяет сформировать информационную диагностическую модель каждого ИПЭ в виде ограниченного геометрического пространства признаков (где признаки – это значения входных и выходных сигналов элемента) в выбранной метрике (в исследовании – евклидово расстояние), с целью последующего анализа поведения данных, а также поиска в них аномалий [10].

Представленная функциональная модель была формализована математически, что позволяет перейти к описанию её алгоритмической основы, приведенной на рисунке 2.

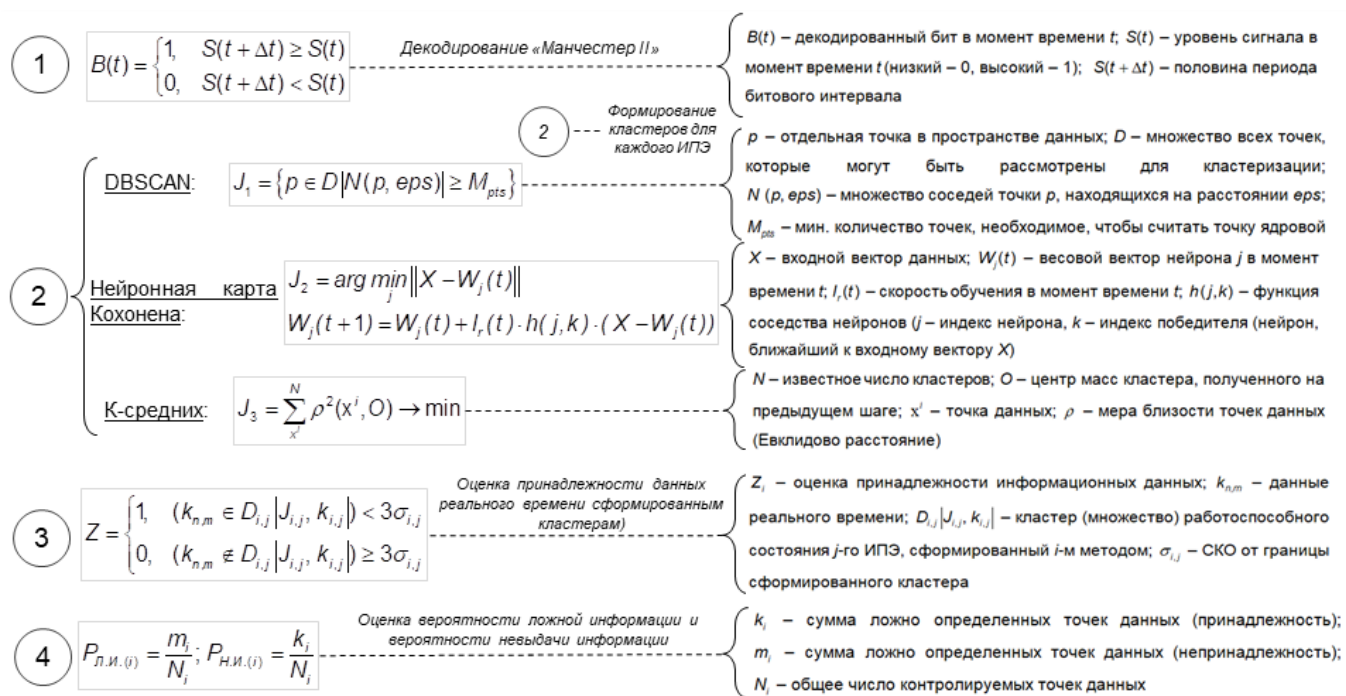


Рисунок 2 – Математическая модель на основе методов машинного обучения в структуре разработанной функциональной модели

Процесс работы функциональной модели включает следующие этапы. На этапе испытаний бортового оборудования слова данных от оконечных устройств, необходимые для обучения модуля технического диагностирования, поступают через микроконтроллер, запрограммированный на декодирование кода «Манчестер II» [11]. Данные поадресно записываются в память, формируя базу

обучающей информации. После создания этой базы модуль выполняет последовательность команд: прием адресных данных от оконечных устройств из памяти; инициализацию процессов создания, обучения и тестирования алгоритма машинного обучения для конкретного адреса; формирование с помощью алгоритма кластера, описывающего работоспособное состояние каждого ИПЭ; сохранение программного кода обученного алгоритма в память команд модуля.

На следующем этапе осуществляется поадресная передача парных декодированных слов данных (входной и соответствующий ему выходной сигнал элемента) на вход алгоритма. Это позволяет проводить техническое диагностирование в реальном времени. Результаты контроля (код состояния «1» или «0», адрес оконечного устройства и подадрес элемента) выводятся для индикации в БАСК.

На рисунке 3 представлена схема модуля технического диагностирования, резервирования и прогнозирования технического состояния ИПЭ БО ВС на основе методов машинного обучения, подключаемого к мультиплексному каналу информационного обмена (МКИО), который состоит из: 1 – микроконтроллер декодирования слов данных «Манчестер II»; 2 – постоянное запоминающее устройство 1 (память данных: хранение адресных обучающих информационных данных); 3 – коммутатор (связь микроконтроллера и нейропроцессора); 4 – нейропроцессор K1879BM8Я NeuroMatrix из линейки процессоров НТЦ «Модуль»; 5 – оперативное запоминающее устройство; 6 – постоянное запоминающее устройство 2 (память команд: хранение обученных адресных моделей машинного обучения); 7, 8 – программаторы; 9 – модуль преобразования электропитания из 27В постоянного тока в 5В, 3,3В, 2В постоянного тока; 10 – постоянное запоминающее устройство 3 (хранение программ автоматического определения параметров обучения алгоритмов; программ автоматического определения параметров фильтрации одномерного фильтра Калмана для каждого ИПЭ); 11 – бортовая автоматизированная система контроля (не входит в состав устройства технического диагностирования); 12 – шлейф подключения к мультиплексному каналу информационного обмена; 13 – блок

прогнозирования (анализ временных рядов и расчет остаточного ресурса);  
 14 – ПЗУ 4 (хранение прогностических моделей и архивов параметров эксплуатации) [12].

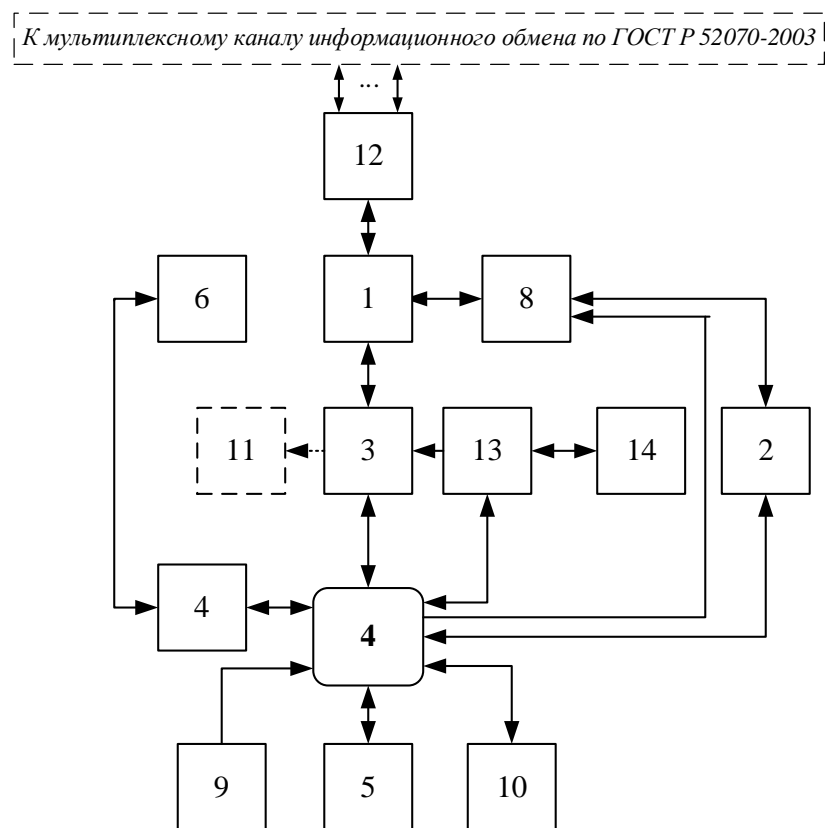


Рисунок 3 – Модуль на основе методов машинного обучения, подключаемый к мультиплексному каналу информационного обмена

Модуль технического диагностирования, резервирования и прогнозирования технического состояния подключается как унифицированное устройство интерфейса к основной и резервной магистральной шине, которая выполнена из кабеля, содержащего витую экранированную пару проводников в защитной оболочке через ответвитель, представляющий собой шлейф (12), состоящий из двух защитных резисторов экрана (2), а также согласующего трансформатора, и трансформатора гальванической развязки.

Принцип работы разработанного модуля [13] основан на автоматическом обучении и последующей работе трёх модифицированных алгоритмов машинного обучения, что обеспечивает контроль информационно-

преобразующих элементов в реальном времени. Работа модуля делится на два основных этапа: этап обучения и этап эксплуатационного контроля.

На этапе испытаний БО по команде нейропроцессора (4), слова данных (СД) от оконечных устройств (ОУ), необходимые для обучения модулей диагностики и прогнозирования, через микроконтроллер (1), запрограммированный на декодирование СД «Манчестер II», поадресно записываются в постоянное запоминающее устройство (ПЗУ) 1 (2). С определенной дискретностью через программатор (8), обращающийся к энергонезависимым ПЗУ (2), обучающие и исторические данные каждого ИПЭ записываются в соответствующие ячейки согласно адресам ОУ и поадресов передаваемых СД. После сбора данных, по команде нейропроцессора (4), обращаясь к ПЗУ 3 (10), запускаются: программа автоматического определения оптимальных параметров обучения диагностических моделей; программа настройки адаптивного фильтра Калмана; программа оптимизации прогностических алгоритмов (LSTM, рекуррентные нейросети) для каждого ИПЭ, с записью их настроек в ОЗУ (5). Далее выполняется поадресный процесс обучения моделей с записью их программ в ПЗУ 2 (6) через программатор (7). Питание устройства осуществляется от модуля преобразования (9). После обучения моделей осуществляется: контроль текущего состояния ИПЭ через анализ принадлежности данных реального времени сформированным кластерам работоспособности; прогнозирование остаточного ресурса через блок (13) [14]. на основе анализа: динамики параметров (температура, вибрация, электропитание); воздействия эксплуатационных факторов; исторических данных из ПЗУ 1 (2).

После завершения обучения модуль переходит в режим оперативного диагностирования. В процессе информационного обмена по магистрали осуществляется поадресный контроль принадлежности текущих данных сформированным ранее кластерам, описывающим работоспособное состояние каждого элемента. Результаты диагностики и прогноза поадресно передаются через коммутатор (3) в БАСК (11), включая: сообщения о текущем состоянии (работоспособность/неисправность); прогнозируемый остаточный ресурс; ранние предупреждения о потенциальных отказах.

Разработан алгоритм технического диагностирования информационно-преобразующих элементов БО ВС на основе методов машинного обучения. Данный алгоритм основан на сборе, обработке и использовании адресных информационных данных из МКИО и сочетает три метода машинного обучения: DBSCAN, K-means и SOM. Ключевой модификацией алгоритма является наличие блок-программ для автоматического определения параметров обучения моделей для каждого элемента, приведенного на рисунке 4.

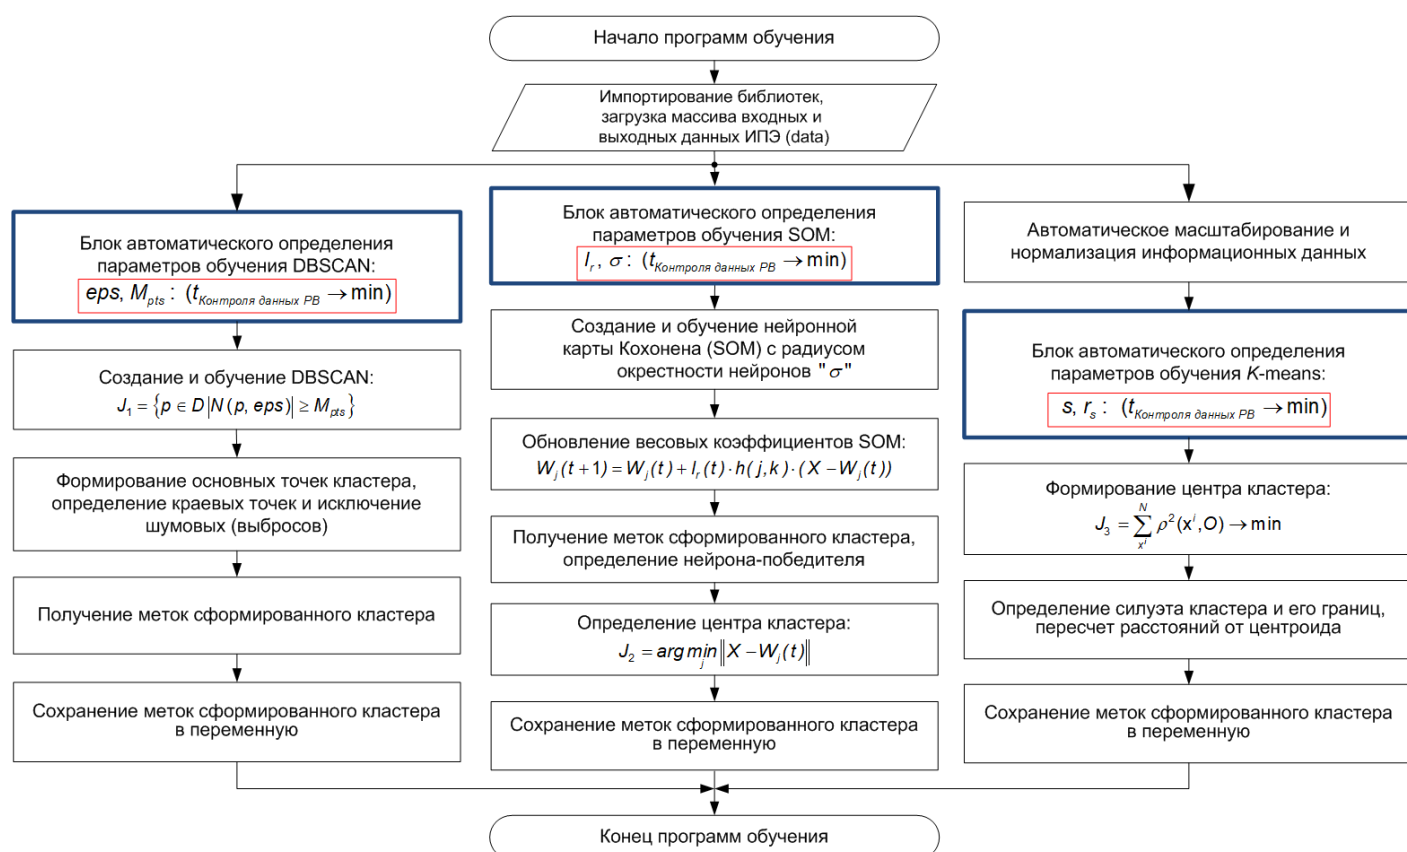


Рисунок 4 – Блок-схема алгоритма машинного обучения

Для реализации прогнозирования технического состояния рассмотрим информационно-преобразующий элемент как детерминированную систему с одним входом  $x$  и одним выходом  $y$ , описываемую функцией преобразования  $y = f(x)$ . Детерминированная система – это система, состояние которой в каждый момент времени однородно описывается функциональными закономерностями [15]. Кластер формируется на основе двухэлементного вектора входных  $X = [x_1, x_2, \dots, x_N]$  и выходных сигналов

$Y = [y_1, y_2, \dots, y_N] = [f(x_1), f(x_2), \dots, f(x_N)]$  элемента, что позволяет создать дискретную (по форме зависимости от времени) информационную (по методу представления) диагностическую модель. При рассмотрении модели поведения объекта в виде информационной диагностической модели последний рассматривается как преобразователь информации или представляет информационную оценку изменений, происходящих в состоянии объекта диагностирования. Такой тип диагностической модели является наиболее универсальным, поскольку не зависит от принципа построения и действия объекта, а характеризует потоки информации о его состоянии или потоки информации, циркулирующие в нем.

Кластер работоспособного ТС  $S_{раб} = \{(x_i, y_i)\}_{i=1}^N, y_i = f(x_i)$ , представленный на рисунке 5, формируется в процессе работы ИПЭ бортового оборудования на этапе испытаний и задается как множество пар  $\{(x_1, y_1), (x_2, y_2), \dots, (x_N, y_N)\}$ .

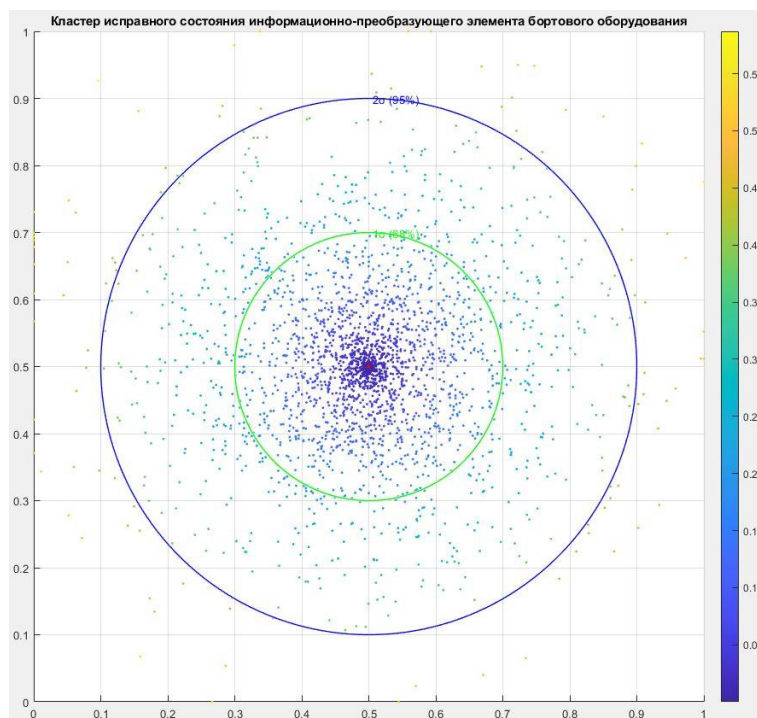


Рисунок 5 – Кластер работоспособного технического состояния информационно-преобразующего элемента бортового оборудования

Сформированный кластер работоспособного технического состояния  $S_{раб}$  (с центром в  $c$  и границей  $\varepsilon$ ) позволяет анализировать динамику текущего

технического состояния  $S_{i\text{текущ}} = \{(x_i, y'_i)\}_{i=1}^N$ ,  $y'_i = f'(x_i)$ , где  $f'(x_i)$  – текущая функция преобразования с элементами деградации за период эксплуатации. Мониторинг расстояния  $D_t = \|s_t - c\|_2$  в сторону границы кластера, даёт возможность прогнозировать техническое состояние элементов бортового оборудования [16].

Для прогнозирования технического состояния объекта используется рекуррентная нейронная сеть с долгосрочной краткосрочной памятью (Long Short-Term Memory, LSTM), представленной на рисунке 6. В качестве входных данных используется временной ряд расстояний между центром кластера и текущей точкой  $D_t = \|s_t - c\|_2$ , что позволяет учитывать динамику изменений состояния во времени. Ключевая особенность архитектуры LSTM заключается в использовании специализированных блоков памяти вместо традиционных нейронов. Каждый блок содержит три управляющих механизма (вентиля): вентиль забывания (forget gate), регулирующий сохранение или удаление информации из состояния ячейки; вентиль входа (input gate), определяющий обновление состояния на основе новых данных; вентиль выхода (output gate), контролирующей формирование выходного сигнала.

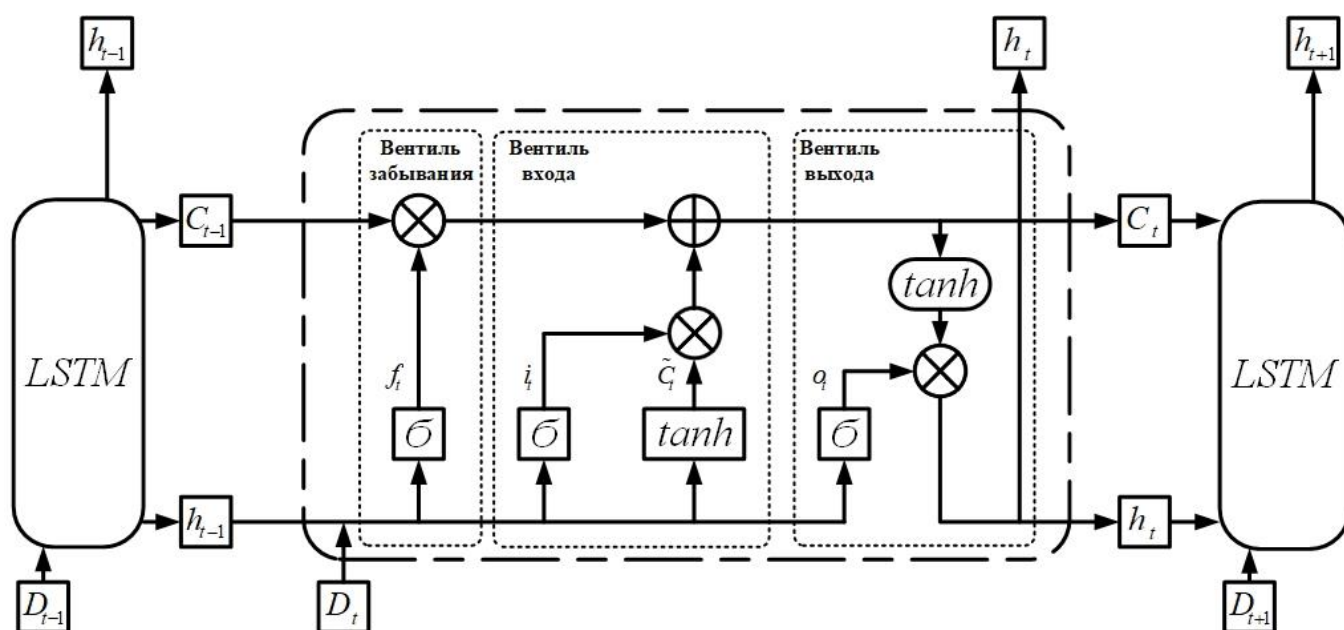


Рисунок 6 – Архитектура нейронной сети LSTM

Математическая модель архитектуры LSTM сети имеет вид (1):

$$\left\{ \begin{array}{l} f_t = \sigma(W_f [h_{t-1}, D_t] + b_f), \\ i_t = \sigma(W_i [h_{t-1}, D_t] + b_i), \\ \tilde{C}_t = \tanh(W_c [h_{t-1}, D_t] + b_c), \\ C_t = f_t \odot C_{t-1} + i_t \odot \tilde{C}_t, \\ o_t = \sigma(W_o [h_{t-1}, D_t] + b_o), \\ h_t = o_t \odot \tanh(C_t). \end{array} \right. \quad (1)$$

где:  $D_t$  - входные данные на текущем шаге;  $h_{t-1}, h_t, h_{t+1}$  - скрытое состояние на предыдущем, текущем и будущем шаге;  $C_{t-1}, C_t$  - состояние памяти на предыдущем и текущем шаге;  $W_f, W_i, W_c, W_o$  - матрица весов;  $b_f, b_i, b_c, b_o$  - векторы смещений;  $f_t$  - сигнал забывающего вентиля;  $i_t$  - сигнал входного вентиля;  $\tilde{C}_t$  - кандидат на обновление памяти;  $o_t$  - сигнал выходного вентиля;  $\sigma, \tanh$  - сигмоидная и гиперболическая функции активации;  $\odot$  - поэлементное умножение.

Выбор архитектуры LSTM обусловлен её способностью эффективно обрабатывать долгосрочные временные зависимости, минимизируя проблему затухающего градиента. [17]. Процесс обучения LSTM-сети осуществляется через адаптивную корректировку весовых коэффициентов каждого элемента архитектуры с использованием алгоритма обратного распространения ошибки через время (Backpropagation Through Time, BPTT), что позволяет сети эффективно запоминать длинные временные последовательности и точно моделировать сложные нелинейные зависимости в данных [18]. Эти свойства особенно ценны для анализа многопараметрических временных рядов данных, поскольку обеспечивают многослойную иерархическую обработку признаков с использованием нелинейных функций активации ( $\sigma, \tanh$ ) и динамическую адаптацию временных масштабов. В результате LSTM-сеть демонстрирует высокую точность прогнозирования, что является перспективным инструментом для решения задач диагностирования и прогнозирования технического состояния. Блок-схема алгоритма представлена на рисунке 7.

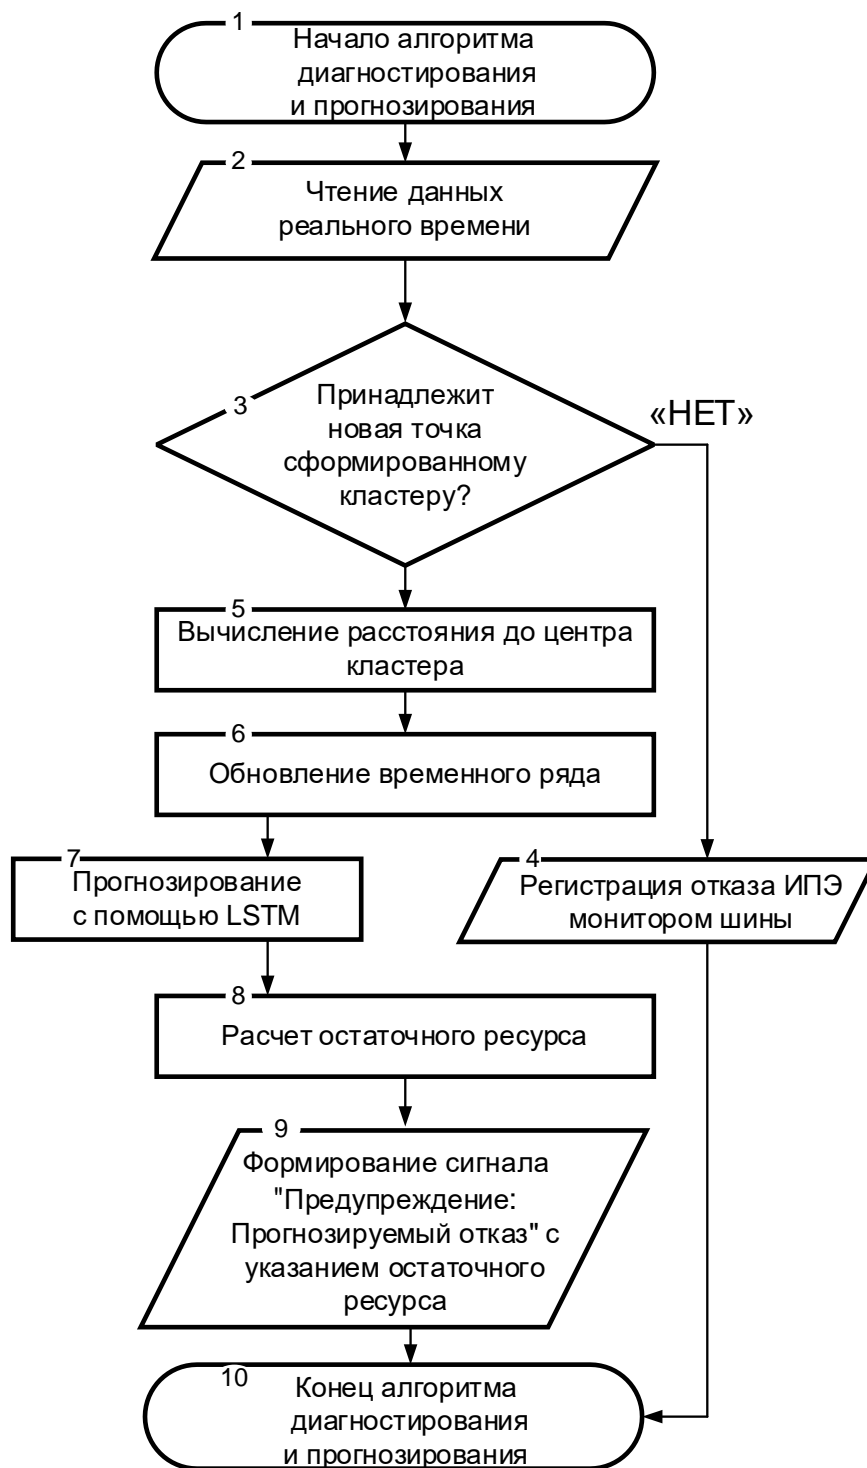


Рисунок 7– Блок-схема алгоритма прогнозирования на основе методов машинного обучения

После завершения алгоритма обучения выполняется алгоритм резервирования информационно-преобразующих элементов, блок-схема которого представлена на рисунке 8. Реализация алгоритма технического диагностирования и резервирования начинается с определения допусков работоспособного состояния ИПЭ –  $\Delta_{уст}$ . Эта операция реализуется на основе технической документации на ИПЭ.

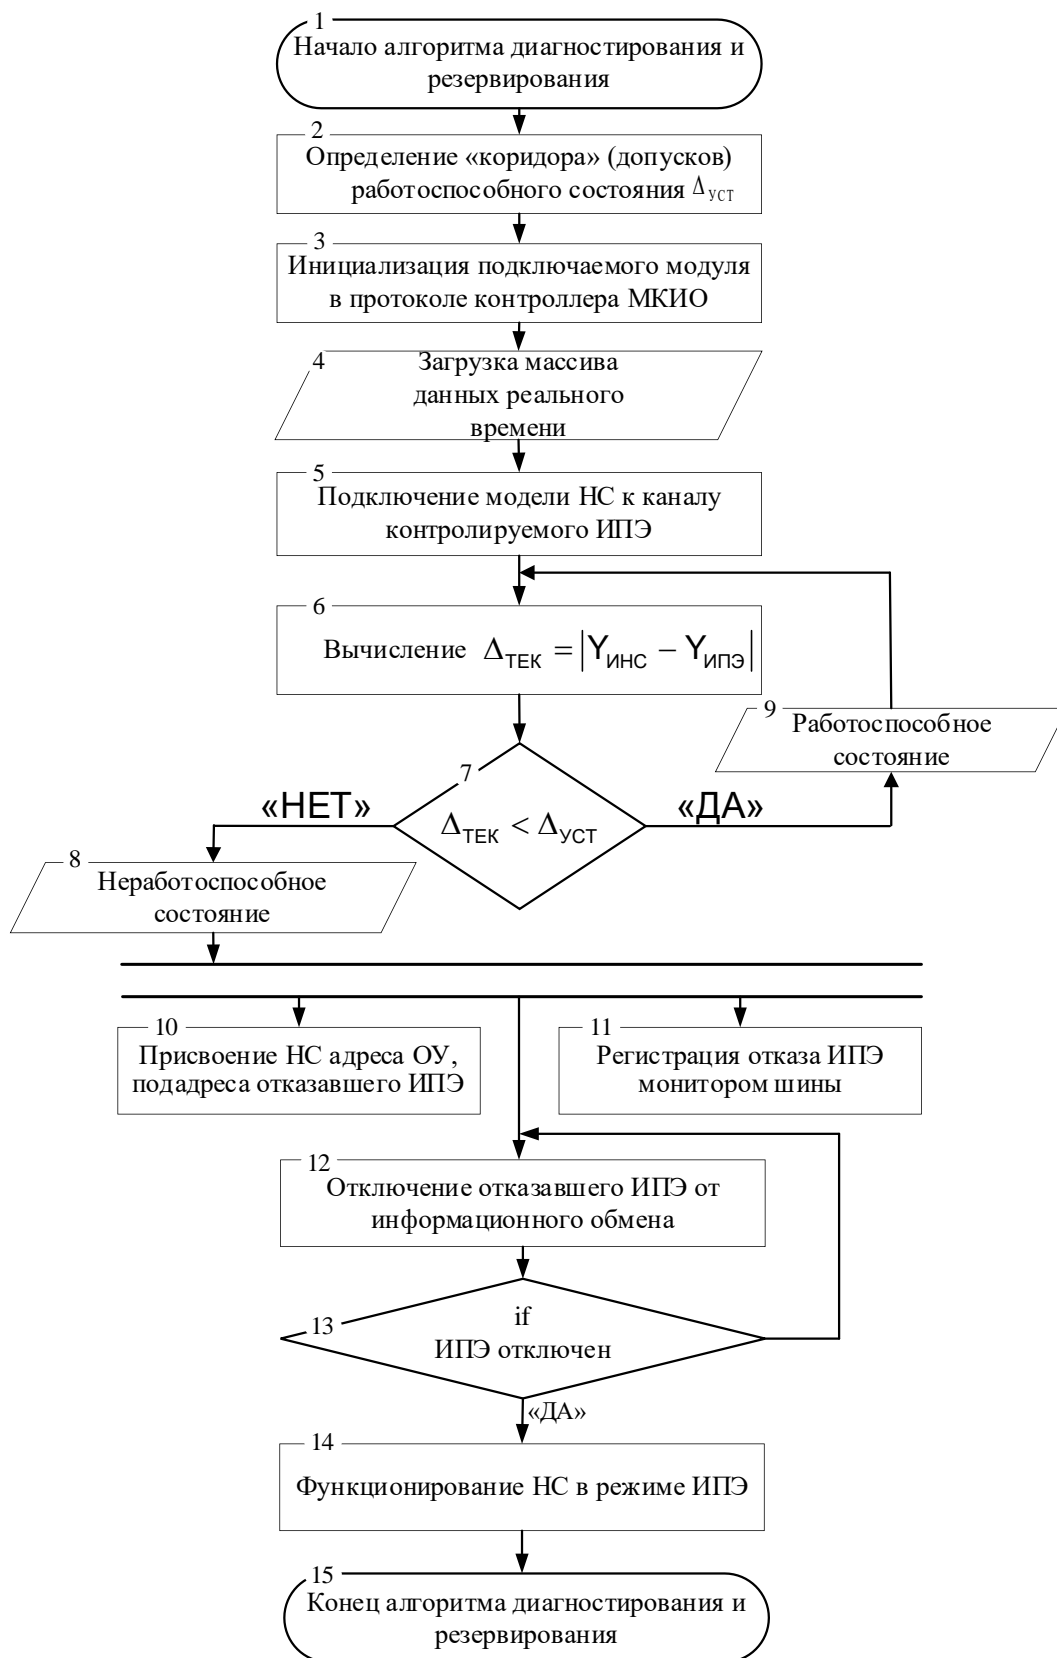


Рисунок 8 – Блок-схема алгоритма диагностирования и резервирования

Основу алгоритма диагностирования и резервирования составляет циклическое сравнение текущей разницы выходных данных информационно-преобразующего элемента и искусственной нейронной сети с установленным допуском на работоспособное состояние.

При текущей разнице, превышающей установленный допуск, элемент признаётся неработоспособным. В этом случае, информационно-преобразующий элемент отключается от информационного обмена, и выполняются следующие операции:

– присвоение искусственной нейронной сети, функционирующей в режиме нагруженного резерва, адреса отказавшего информационно-преобразующего элемента;

– регистрация отказа в бортовом устройстве регистрации и индикация экипажу на многофункциональном индикаторе информации об отказе;

– отключение отказавшего элемента от информационного обмена.

При выполнении последнего – искусственная нейронная сеть функционирует вместо отказавшего информационно-преобразующего элемента, что является результатом работы алгоритма диагностирования и резервирования.

Для оценки эффективности разработанной системы был проведен полунатурный эксперимент по имитации подключения к МКИО и диагностированию блока БУП-Д-2А системы СДУ-Д. В качестве исследуемого канала преобразования информационных сигналов был выбран основной канал управления блока БУП-Д-2А: проводился сбор оцифрованных сигналов входа и выхода на всем рабочем диапазоне функционирования имитаторов, с целью формирования кластеров, описывающих эту функциональную зависимость (работоспособное состояние), с дальнейшей проверкой принадлежности данных реального времени сформированным кластерам. Схема управления блоком, а также, структурно-функциональная схема экспериментального стенда представлены на рисунке 9 и рисунке 10 соответственно.




Рисунок 9 – Схема управления блока БУП-Д-2А

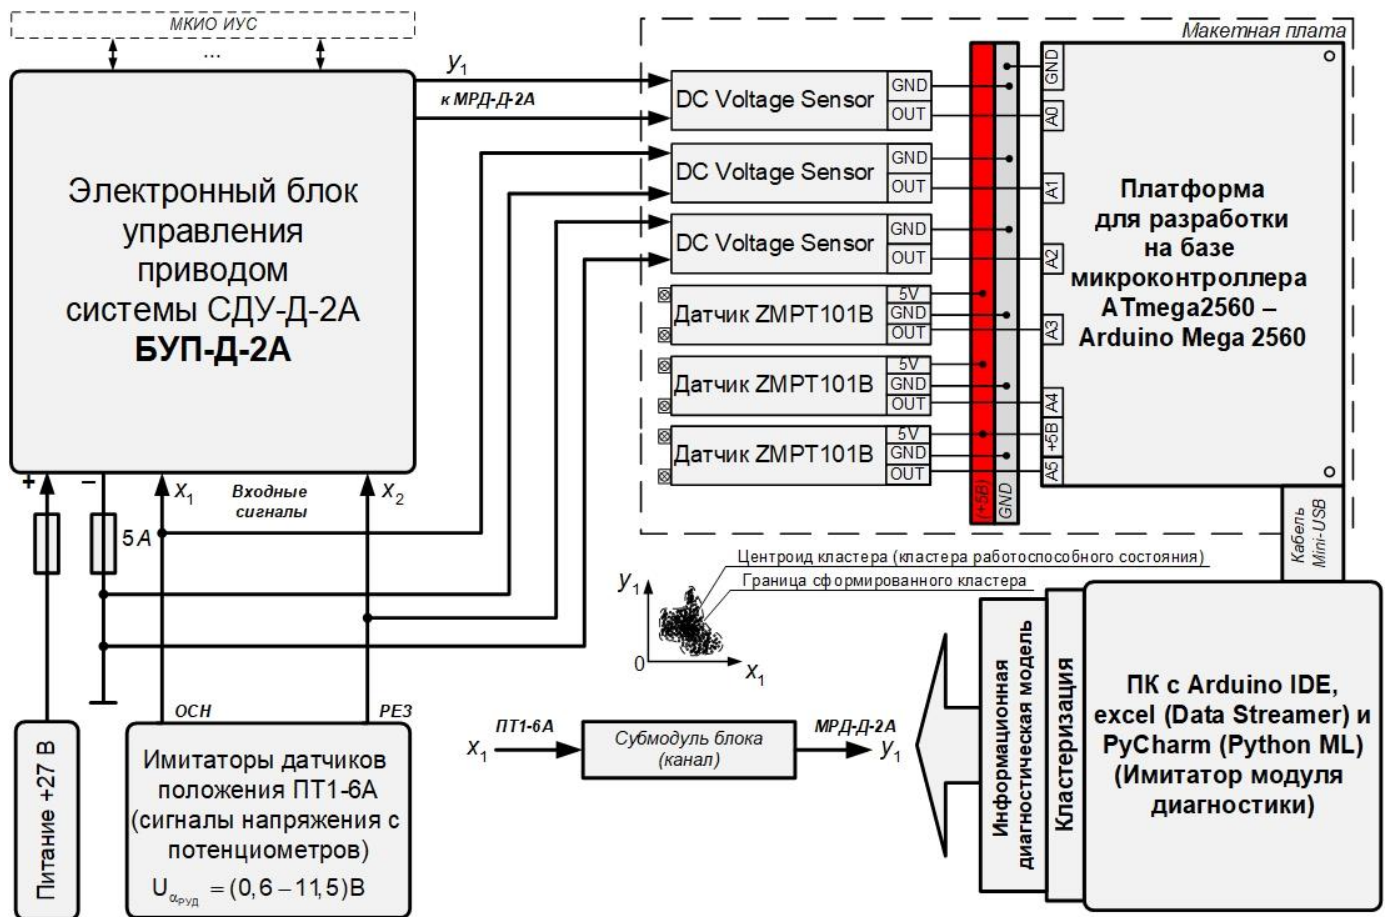


Рисунок 10 – Структурно-функциональная схема экспериментального стенда

Входным сигналом блока БУП-Д-2А является напряжение постоянного тока от датчиков положения ручки управления ПТ1-6А.

В составе экспериментального стенда используются лабораторный источник питания постоянным током GPS-73303А, генератор сигналов специальной формы АКИП-3402, контроллер Arduino MEGA-2560, датчики ZMPT101В и DC-voltage sensor, малоинерционные предохранители ПМ-5, авиационные выключатели линий питания ВГ-15К, макетная плата, комплект соединительных проводов, кабель USB-mini, ноутбук. Внешний вид экспериментального стенда представлен на рисунке 11.




Рисунок 11 – Экспериментальный стенд

При проведении многофакторного эксперимента необходимо определить основные факторы, существенно влияющие на выходной параметр – время контроля принадлежности информационных данных реального времени сформированным кластерам. Кодирование факторов необходимо для перевода натуральных факторов в безразмерные величины, для последующей обработки результатов проведенных экспериментов и определения коэффициентов уравнения регрессии.

Обозначим нижний уровень фактора  $z_i$  через  $z_i^-$ , а верхний уровень – через  $z_i^+$  (т.е.  $z_i \in [z_i^-; z_i^+], i = 1, \dots, k$ ). Для перевода натуральных переменных в кодовые  $x_i$  заполним таблицу кодирования переменных на трех уровнях. Связь между кодовым и натуральным выражением фактора задается формулой (2):

$$x_i = \frac{z_i - z_i^0}{\lambda_i}, \quad (2)$$

где  $z_i$  – натуральное значение фактора;  $z_i^0$  – значение  $i$ -го фактора на нулевом уровне;  $\lambda_i$  – интервал варьирования  $i$ -го фактора, который рассчитан с помощью соотношений (3):

$$x_i^0 = \frac{z_i^+ + z_i^-}{2}, \lambda_i = \frac{z_i^+ - z_i^-}{2}. \quad (3)$$

При таком кодировании все новые переменные будут принимать значения от  $-1$  до  $+1$ , т.е.  $x_i = [-1; +1], i = \overline{1, k}$ . Кодирование факторов представлено в таблице 1.

Таблица 1

Кодирование факторов при проведении эксперимента.

Наименование и обозначение факторов	Уровни варьирования			Интервалы варьирования, $\lambda_i$	Зависимость кодированной переменной от натуральной
	$z_i^-$	$z_i^0$	$z_i^+$		
Уровень силы тока с имитатора датчика положения ПТ1-6А – $z_1$	0,5	1	1,5	0,5	$x_1 = \frac{z_1 - 1}{0,5}$
Уровень внешнего возмущающего воздействия (шума) – $z_2$	0	1	2	1	$x_2 = \frac{z_2 - 1}{1}$
Уровень питающего напряжения объекта контроля – $z_3$	27	28	29	1	$x_3 = \frac{z_3 - 28}{1}$

В результате проведенных исследований получена математическая модель времени контроля данных реального времени. Математическая модель имеет вид (4):

$$y = 28,41 - 11,78z_1 - 44,37z_2 - 0,51z_3 + 45,08z_1z_2 + 0,26z_1z_3 + 1,46z_2z_3 - 1,46z_1z_2z_3, \quad (4)$$

где:  $z_1$  – уровень силы тока с имитатора датчика положения ПТ1-6А;  $z_2$  – уровень внешнего возмущающего воздействия (шума);  $z_3$  – уровень питающего напряжения объекта контроля.

На основе разработанного алгоритма диагностирования и прогнозирования ИПЭ бортового оборудования ВС, на примере собранных информационных данных было разработано специальное программное обеспечение (СПО) «ДИАГНОСТИКА-93» с использованием языка программирования Python [19, 20]. Результат работы СПО на тестовых данных при проведении экспериментальных исследований, представлен на рисунке 15. Как видно из рисунка 15, данные, принадлежащие кластеру, который описывает работоспособное состояние канала преобразования информации «БУП-Д-2А – МРД-Д-2А», помечаются зеленым цветом. Также, для данных, которые разработанным алгоритмом

определяются принадлежащими кластерам работоспособного состояния, в реальном времени выводится результат в виде информационных сообщений, представленных в нижней части рисунка 12.

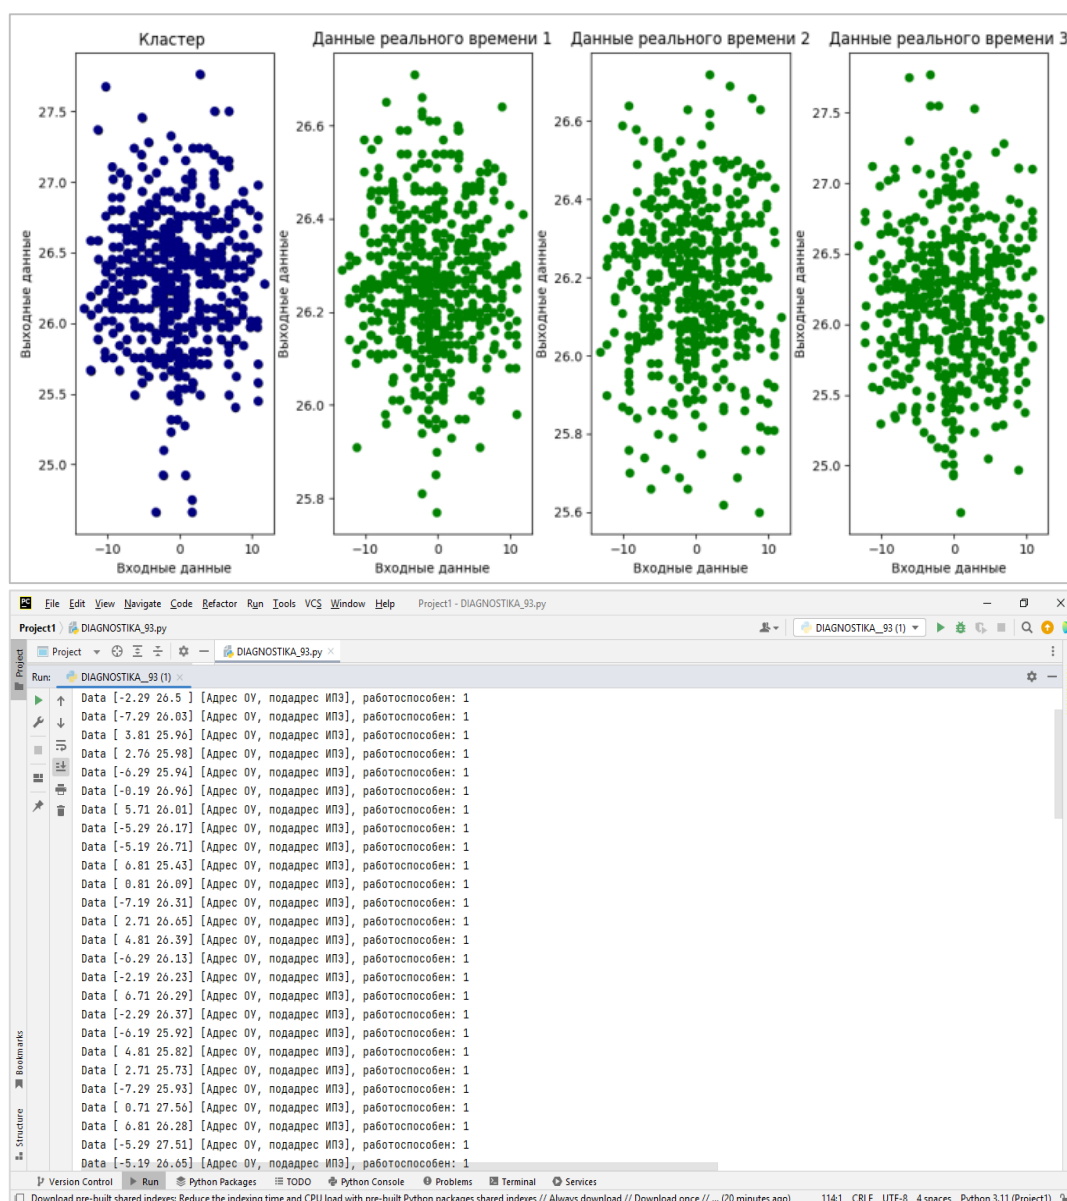


Рисунок 12 – Вывод специального программного обеспечения результата контроля при проверке данных реального времени, соответствующих работоспособному состоянию информационно-преобразующего элемента («1»)

Результат работы СПО на тестовых данных, полученных в реальном времени при проведении полунатурного эксперимента, а также отличных от эталонных данных (выходной сигнал целенаправленно для проверки уменьшен программно), представлен на рисунке 13. Как видно из правой части рисунка 13, данные, не принадлежащие кластеру, который описывает работоспособное

состояние канала преобразования информации «БУП-Д-2А – МРД-Д-2А», помечаются красным цветом. Также, для данных, которые разработанным алгоритмом определяются не принадлежащими кластеру работоспособного состояния, в реальном времени выводится результат в виде информационных сообщений, представленных в нижней части рисунка 13.




Рисунок 13 – Вывод СПО результата контроля при проверке данных реального времени, соответствующих неработоспособному состоянию ИПЭ («0»)

Результат работы СПО [21] при превышении внешних возмущающих воздействиях свыше 10% относительно сигнала, представлен на рисунке 14.



вычислительные ресурсы нейронной сети, находящихся в нагруженном резерве [22].

Отказ индицируется посредством контроллера шины на многофункциональный индикатор экипажу и регистрируется в бортовом устройстве регистрации полётных данных в виде адреса отказавшего информационно-преобразующего элемента, что позволяет оперативно устранить отказ путём замены отказавшего элемента [23].

При подключении питания и включении бортового оборудования, алгоритм в виде специального программного обеспечения снова осуществляет постоянное сравнение сигналов уже исправного элемента и искусственной нейронной сети и автоматически переключает функционирование на ИПЭ. Так осуществляется динамическое резервирование информационно-преобразующего элемента бортового оборудования на основе искусственной нейронной сети.

На рисунке 15 представлена диаграмма среднего времени поиска места отказа –  $t_{по}$  при возникновении отказа в полете блока управления приводом БУП-Д-2А системы СДУ-Д с применением СПО и без него.

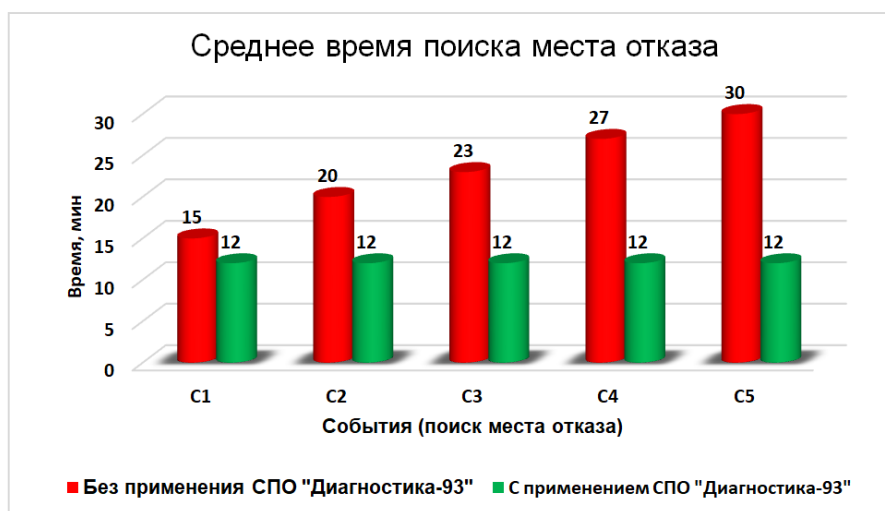


Рисунок 15 – Среднее время поиска места отказа

При отказе блока БУП-Д-2А системы СДУ-Д, который выполняет свои функции через МКИО, результат контроля на МФИ в реальном времени отображается в виде информационного сообщения «Отказ СДУ-Д». Система СДУ-Д состоит из четырех отдельных блоков и агрегатов, определить отказы которых

без подключения наземного автоматизированного рабочего места (АРМ) – затруднительно. Вследствие этого, специалистами инженерно-авиационной службы организовывается метод блочной замены агрегатов, исходя из анализа частоты отказов того, или иного элемента, и проверки работоспособности системы после замены.

Событиями, указанными на гистограмме, представленной рисунком 15, являются:

С1 – отказ блока БУП-Д-2А выявлен на первом шаге проверки.

С2 – отказ блока БУП-Д-2А выявлен на втором шаге проверки.

С3 – отказ блока БУП-Д-2А выявлен на третьем шаге проверки.

С4 – отказ блока БУП-Д-2А выявлен на четвертом шаге проверки.

С5 – отказ блока БУП-Д-2А выявлен на пятом шаге проверки, при котором возникла необходимость подключения наземного АРМ для проверки функционирования системы СДУ-Д («скрытый отказ»).

Из диаграммы видно, что применение СПО позволяет сократить среднее время поиска места отказа на 3 минуты относительно среднего времени поиска места отказа при определении отказа на первом шаге проверки, а также на 18 минут относительно среднего времени поиска места отказа при определении отказа на пятом шаге проверки.

На рисунке 16 представлена диаграмма относительного сокращения среднего времени поиска места отказа.

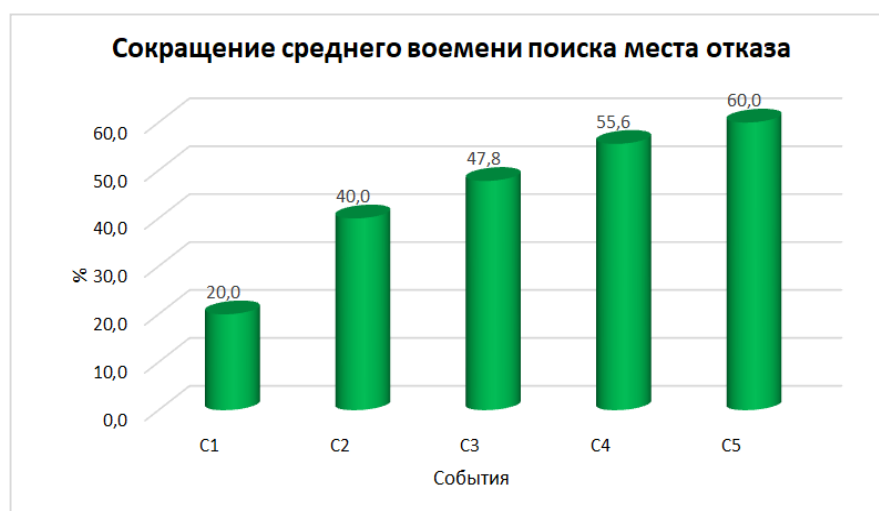


Рисунок 16 – Сокращение среднего времени поиска места отказа

Диаграмма демонстрирует сокращение среднего времени поиска места отказа при применении разработанного СПО, что позволит снизить среднее время восстановления ВС и повысить коэффициент технической готовности ВС.

Проведенный полунатурный эксперимент подтвердил эффективность разработанного СПО «ДИАГНОСТИКА-93», продемонстрировав сокращение среднего времени поиска места отказа на 3-18 минут в зависимости от выбранного метода поиска места отказа.

Таким образом, в представленной работе разработана и экспериментально обоснована комплексная система встроенного технического диагностирования, резервирования и прогнозирования технического состояния бортового оборудования воздушных судов. Основными преимуществами являются:

1. Повышение глубины и точности диагностики за счет применения ансамбля методов машинного обучения без учителя (DBSCAN, K-means, SOM) с мажоритарным принципом принятия решений система обеспечивает автоматическое построение диагностических моделей любой сложности и однозначную идентификацию отказавшего информационно-преобразующего элемента на уровне конструктивно-съёмной единицы.

2. Реализация функций прогнозирования и резервирования. Использование рекуррентной нейронной сети с долгосрочной краткосрочной памятью (LSTM) позволяет прогнозировать остаточный ресурс элементов бортового оборудования на основе анализа временных рядов. В случае отказа осуществляется динамическое резервирование путем автоматического переключения на программную нейросетевую модель, функционирующую в нагруженном резерве, что повышает отказоустойчивость комплекса бортового оборудования.

3. Аппаратно-алгоритмическая реализация. Предложена архитектура подключаемого модуля на базе нейропроцессора, интегрируемого в магистральный последовательный канал. Разработанные алгоритмы включают автоматический подбор параметров обучения и фильтрации (фильтр Калмана)

для каждого ИПЭ, что обеспечивает адаптивность и устойчивость системы к внешним возмущениям.

4. Экспериментальное подтверждение эффективности. Проведенный полунатурный эксперимент на примере блока БУП-Д-2А системы СДУ-Д с использованием созданного программного обеспечения «ДИАГНОСТИКА-93» доказал практическую работоспособность системы. Установлено, что её применение позволяет сократить среднее время поиска места отказа на 3–18 минут в зависимости от сценария, что ведет к снижению времени восстановления воздушного судна и повышению коэффициента технической готовности.

Таким образом, работа представляет законченное научно-техническое решение, интегрирующее передовые методы машинного обучения в бортовые системы контроля. Разработанная система вносит существенный вклад в повышение безопасности, надежности и эксплуатационной эффективности авиационной техники за счет перехода от реактивного обслуживания по факту отказа к прогностическому и адаптивному комплексному управлению техническим состоянием.

---

### **Конфликт интересов**

Авторы заявляют об отсутствии конфликта интересов.

### **Conflict of interest**

The authors declare no conflict of interest.

### **Список источников**

1. Мозгалевский, А.В., Калявин В.П., Костанди Г.Г. Диагностирование электронных систем / Под ред. А.В. Мозгалевского. – Л.: Судостроение, 1984. – 224 с.
2. ГОСТ 24029-80. Техническая диагностика. Категории контролепригодности объектов диагностирования. – М.: Издательство стандартов, 1980. – 11 с.

3. Голубец, А.А. Внедрение машинного обучения и искусственного интеллекта в авиационной отрасли с целью повышения безопасности полетов // Интернаука. – 2024. – № 41-1(358). – С. 34-36.

4. Применение методов машинного обучения при решении задач технической диагностики / В.Н. Клячкин, И.Н. Карпунина, Ю.Е. Кувайскова, А.С. Хорева // Научный вестник УИ ГА. – 2016. – № 8. – С. 158–161.

5. Кушнирук, А.С. Диагностика моторно-осевых подшипников колесно-моторного блока с нейросетевой эталонной моделью: специальность 05.22.07 «Подвижной состав железных дорог, тяга поездов и электрификация»: диссертация на соискание ученой степени кандидата технических наук / Кушнирук Алексей Сергеевич. – Хабаровск, 2021. – 155 с.

6. Макаров, А.С. Алгоритмы контроля и диагностики систем управления авиационными ГТД на основе нейросетевых моделей и нечеткой логики: специальность 05.13.01 «Системный анализ, управление и обработка информации (по отраслям)»: диссертация на соискание ученой степени кандидата технических наук / Макаров Андрей Сергеевич. – Уфа, 2011. – 207 с.

7. Легконогих, Д.С. Применение нейросетевых технологий в системах диагностики авиационных силовых установок / Д.С. Легконогих // Известия Самарского научного центра Российской академии наук. – 2012. – Т. 14. – № 4-2. – С. 639-643.

8. Добродеев, И.П. Повышение эффективности нейросетевых моделей в системах диагностики технического состояния газотурбинных двигателей на основе функциональной адаптации: специальность 05.13.01 «Системный анализ, управление и обработка информации (по отраслям)»: диссертация на соискание ученой степени кандидата технических наук / Добродеев Илья Павлович. – Рыбинск, 2010. – 218 с.

9. ГОСТ Р 52070-2003. Интерфейс магистральный последовательный системы электронных модулей. Общие требования. «Издательство стандартов». Москва: Стандартинформ, 2003. 27 с.

10. Вьюгин, В.В. Математические основы машинного обучения и прогнозирования. Изд. 2-е, испр. и доп. М.: МЦНМО, 2018. – 384 с.

11. Свидетельство о государственной регистрации программы для ЭВМ № 2023669933 Российская Федерация. Программа декодирования данных «Манчестер-2» информационно-управляющей системы воздушного судна: № 2023669137: заявл. 15.09.2023: опубл. 22.09.2023 / А.С. Букирёв.

12. Патент № 242787 С1 Российская Федерация, МПК G06F 11/00, G06N 20/00, G05B 23/02. Устройство диагностирования и прогнозирования технического состояния комплекса бортового оборудования воздушных судов на основе методов машинного обучения: № 2025135065: заявл. 08.12.2025: опубл. 10.04.2026 / А.Д. Савчук.

13. Патент № 2816667 С1 Российская Федерация, МПК G06F 11/00, G06N 20/00, G05B 23/02. Способ диагностирования комплекса бортового оборудования воздушных судов на основе машинного обучения и устройство для его осуществления: № 2023116413: заявл. 21.06.2023: опубл. 03.04.2024 / А.С. Букирёв, А.Ю. Савченко, С.В. Ипполитов [и др.].

14. Свидетельство о государственной регистрации программы для ЭВМ № 2024692313 Российская Федерация. Программа оценки технического состояния комплекса бортового оборудования на основе прогнозирования контролируемого диагностического параметра с использованием рекуррентной нейронной сети с долгой краткосрочной памятью: № 2024691930: заявл. 24.12.2024: опубл. 27.12.2024 / А.Д. Савчук.

15. Кувайскова, Ю.Е. Применение ансамблевых методов машинного обучения для прогнозирования технического состояния объекта /Ю.Е. Кувайскова // Известия Самарского научного центра Российской академии наук. – 2021. – Т. 23, № 1(99). – С. 111-114.

16. Волков, В.Л. Моделирование процессов и систем в приборостроении: учебное пособие для студентов технических специальностей дневной, вечерней и заочной формы обучения / В.Л. Волков; Арзамасский политехнический институт. – Арзамас: ООО «Ассоциация ученых», 2008. – 143 с.

17. Прогнозирование качества функционирования технического объекта с использованием машинного обучения / М.И. Корнилова, С.В. Бусыгин,

В.Н. Ковальногов, В.Н. Клячкин // Надежность и качество сложных систем. – 2023. – № 4(44). – С. 152-158.

18. Bengio, Y., Simard, P., Frasconi, P. Learning Longterm Dependencies with Gradient Descent // IEEE Transactions on Neural Networks. 1994. №2. p. 157 – 166.

19. Wei, W., Li, P. Multi-Channel LSTM with Different Time Scales for Foreign Exchange Rate Prediction. Proceedings of the international conference on Advanced Information Science and System. 2019.

20. Исаев, Г.Г. Интеллектуальные информационные технологии в системах технической диагностики авиационной техники / Г.Г. Исаев, Н.П. Козак // Информационные технологии в образовании: Сборник научных трудов. – Ульяновск: Издатель Качалин Александр Васильевич, 2018. – С. 57-61.

21. Свидетельство о государственной регистрации программы для ЭВМ № 2024664709. Российская Федерация. Программа технического диагностирования информационно-преобразующих элементов бортового оборудования авиационного комплекса на основе машинного обучения без учителя с автоматическим определением параметров обучения моделей «ДИАГНОСТИКА-93»: № 2024662926: заявл. 06.06.2024: опубл. 24.06.2024 / А.С. Букирёв.

22. Федоринов А. Ю. Метод повышения точности и надёжности навигационно-измерительных систем на основе комплексной оптимально-инвариантной фильтрации произвольных сигналов в условиях избыточности устройств обработки информации / А.Ю. Федоринов, Ю.П. Иванов // Труды МАИ. – 2024. – № 139.

23. Букирёв А.С. Способ диагностирования комплекса бортового оборудования воздушных судов на основе машинного обучения / А.С. Букирёв // Труды МАИ. – 2023. – № 133.

## References

1. Mozgalevsky A.V., Kalyavin V.P., Kostandi G.G. Diagnostics of electronic systems / edited by A.V. Mozgalevsky. – L.: Sudostroenie, 1984. – 224 p.

2. GOST 24029-80. Technical diagnostics. Categories of controllability of diagnostic objects. – M.: Publishing House of Standards, 1980. – 11 p.

3. Golubets, A.A. Introduction of machine learning and artificial intelligence in the aviation industry in order to improve flight safety A.A. Golubets // Internauka. – 2024. – № 41-1(358). – Pp. 34-36.

4. Application of machine learning methods in solving technical diagnostics problems / V.N. Klyachkin, I.N. Karpunina, Yu.E. Kuvaiskova, A.S. Khoreva // Scientific Bulletin of the Institute of Applied Sciences, 2016, No. 8, pp. 158-161.

5. Kushniruk, A.S. Diagnostics of motor-axial bearings of a wheel-motor unit with a neural network reference model: specialty 05.22.07 "Rolling stock of railways, train traction and electrification": dissertation for the degree of candidate of Technical Sciences / Kushniruk Alexey Sergeevich. – Khabarovsk, 2021. – 155 p.

6. Makarov, A.S. Algorithms for monitoring and diagnostics of aviation GTE control systems based on neural network models and fuzzy logic: specialty 05.13.01 "System analysis, management and information processing (by industry)": dissertation for the degree of Candidate of Technical Sciences / Makarov Andrey Sergeevich. Ufa, 2011. – 207 p.

7. Legkonogikh, D. N. According to S. N. The application of neural network technologies in diagnostic systems of aviation power plants / D. N. According to S. N. Legkonogikh // Proceedings of the Samara Scientific Center of the Russian Academy of Sciences. – 2012. - T. N. 14. – № 4-2. -pp. 639-643.

8. Dobrodeev, I.P. Improving the efficiency of neural network models in systems for diagnosing the technical condition of gas turbine engines based on functional adaptation: specialty 05.13.01 "System analysis, management and information processing (by industry)": dissertation for the degree of Candidate of Technical Sciences / Dobrodeev Ilya Pavlovich. – Rybinsk, 2010. – 218 p.

9. GOST R 52070-2003. The backbone serial interface of the electronic module system. General requirements. Publishing House of Standards. Moscow: Standartinform, 2003. 27 p.

10. Vyugin, V.V. Mathematical foundations of machine learning and forecasting. 2nd Ed., ispr. and add. Moscow: ICNMO, 2018. – 384 p.

11. Certificate of state registration of a computer program No. 2023669933 Russian Federation. The Manchester-2 data decoding program of the aircraft

information and control system: No. 2023669137: application 15.09.2023: published 22.09.2023 / A.S. Bukirev.

12. Patent No. 242787 C1 Russian Federation, IPC G06F 11/00, G06N 20/00, G05B 23/02. A device for diagnosing and predicting the technical condition of an aircraft on-board equipment complex based on machine learning methods: No. 2025135065: application 08/12/2025: published 10/04/2026 / A.D. Savchuk

13. Patent No. 2816667 C1 Russian Federation, IPC G06F 11/00, G06N 20/00, G05B 23/02. A method for diagnosing a complex of on-board equipment of aircraft based on machine learning and a device for its implementation: No. 2023116413: application 06/21/2023: published 04/03/2024 / A.S. Bukirev, A.Yu. Savchenko, S.V. Ippolitov [et al.].

14. Certificate of state registration of a computer program No. 2024692313 Russian Federation. A program for assessing the technical condition of an on-board equipment complex based on predicting a controlled diagnostic parameter using a recurrent neural network with long-term short-term memory: No. 2024691930: application 24.12.2024: published 27.12.2024 / A.D. Savchuk.

15. Kuvaiskova, Yu. N.E. Application of ensemble machine learning methods for predicting the technical condition of an object /Yu. n.E. Kuvaiskova / / Proceedings of the Samara Scientific Center of the Russian Academy of Sciences. – 2021. - T. N. 23, No. 1(99). -pp. 111-114.

16. Volkov, V.L. Modeling of processes and systems in instrument engineering: a textbook for students of technical specialties of full-time, evening and correspondence education / V.L. Volkov; Arzamas Polytechnic Institute. Arzamas: Association of Scientists, LLC, 2008, 143 p.

17. Forecasting the quality of functioning of a technical facility using machine learning / M.I. Kornilova, S.V. Busygin, V.N. Kovalnogov, V.N. Klyachkin // Reliability and quality of complex systems. – 2023. – № 4(44). – Pp. 152-158.

18. Bengio, Y., Simard, P., Frasconi, P. Learning Longterm Dependencies with Gradient Descent // IEEE Transactions on Neural Networks. 1994. №2. p. 157 – 166.

19. Wei, W., Li, P. Multi-Channel LSTM with Different Time Scales for Foreign Exchange Rate Prediction. Proceedings of the international conference on Advanced Information Science and System. 2019.

20. Isaev, G.G. Intelligent information technologies in systems of technical diagnostics of aviation equipment / G.G. Isaev, N.P. Kozak // Information technologies in education: Collection of scientific papers. Ulyanovsk: Publisher Kachalin Alexander Vasilyevich, 2018. pp. 57-61.

21. Certificate of state registration of a computer program № 2024664709. Russian Federation. The program of technical diagnostics of information-transforming elements of onboard equipment of the aviation complex based on machine learning without a teacher with automatic determination of training parameters of models "DIAGNOSTICS-93": № 2024662926: application 06.06.2024: published 24.06.2024 / A.S. Bukirev.

22. Fedorinov A. Y., Ivanov Yu.P. A method for improving the accuracy and reliability of navigation and measurement systems based on complex optimally invariant filtering of arbitrary signals in conditions of redundancy of information processing devices / A.Y. Fedorinov, Yu.P. Ivanov // Proceedings of MAI. - 2024. - No. 139.

23. Bukirev A.S. A method for diagnosing a complex of on-board equipment of aircraft based on machine learning / A.S. Bukirev // Proceedings of MAI. – 2023. – No. 133.

### **Информация об авторах**

**Андрей Дмитриевич Савчук**, адъюнкт кафедры эксплуатации авиационного оборудования, Военный учебно-научный центр Военно-воздушных сил «Военно-воздушная академия им. проф. Н.Е. Жуковского и Ю.А. Гагарина», г. Воронеж, Россия.

**Андрей Юрьевич Савченко**, кандидат технических наук, доцент, доцент кафедры эксплуатации авиационного оборудования, Военный учебно-научный центр Военно-воздушных сил «Военно-воздушная академия им. проф. Н.Е. Жуковского и Ю.А. Гагарина», г. Воронеж, Россия.

**Семен Анатольевич Миронов**, адъюнкт кафедры эксплуатации авиационного оборудования, Военный учебно-научный центр Военно-воздушных

сил «Военно-воздушная академия им. проф. Н.Е. Жуковского и Ю.А. Гагарина», г. Воронеж, Россия.

**Александр Сергеевич Букирёв**, кандидат технических наук, преподаватель кафедры автоматизации управления летательными аппаратами (и вычислительных систем), Военный учебно-научный центр Военно-воздушных сил «Военно-воздушная академия им. проф. Н.Е. Жуковского и Ю.А. Гагарина», г. Воронеж, Россия; e-mail: [bukirev@inbox.ru](mailto:bukirev@inbox.ru)

### Information about the authors

**Andrey D. Savchuk**, Adjunct Department of Aviation Equipment Operation Military Training and Research Center of the Air Force, MESC AF «N.E. Zhukovsky and Y.A. Gagarin Air Force Academy», Voronezh, Russia;

**Andrey Y. Savchenko**, Ph.D. in Technical Sciences, Docent; Associate Professor of the Department of Aviation Equipment Operation Military Training and Research Center of the Air Force, MESC AF «N.E. Zhukovsky and Y.A. Gagarin Air Force Academy», Voronezh, Russia;

**Semyon A. Mironov**, Adjunct Department of Aviation Equipment Operation Military Training and Research Center of the Air Force, MESC AF «N.E. Zhukovsky and Y.A. Gagarin Air Force Academy», Voronezh, Russia;

**Alexander S. Bukirev**, Ph.D. in Technical Sciences, Lecturer at the Department of Aircraft Control Automation (and Computing Systems) Military Training and Research Center of the Air Force, MESC AF «N.E. Zhukovsky and Y.A. Gagarin Air Force Academy», Voronezh, Russia; e-mail: [bukirev@inbox.ru](mailto:bukirev@inbox.ru);

---

Получено 21 декабря 2025 ● Принято к публикации 31 марта 2026 ● Опубликовано 30 апреля 2026  
Received 21 December 2025 ● Accepted 31 March 2026 ● Published 30 April 2026

---