

УДК 629.735

DOI: 10.26467/2079-0619-2024-27-6-21-41

Методика диагностирования технического состояния авиационных газотурбинных двигателей с применением рекуррентных нейронных сетей (RNN) и длинно-краткосрочной памяти (LSTM)

О.Ф. Машошин¹, Г. Гусейнов¹, А.С. Засухин¹

¹Московский государственный технический университет гражданской авиации,
г. Москва, Россия

Аннотация: В данной работе представлена методика диагностирования технического состояния авиационных газотурбинных двигателей (ГТД) с использованием рекуррентных нейронных сетей (RNN) и сетей с длинно-краткосрочной памятью (LSTM). Основное внимание уделено сравнению эффективности данных моделей для прогноза ключевых параметров работы ГТД, таких как вибрации, температуры газа перед турбиной и частоты вращения роторов низкого и высокого давления. В процессе исследования проведена тщательная очистка и нормализация данных, включающая обработку пропущенных значений, нормализацию методом Min-Max Scaling, удаление выбросов, декорреляцию данных и сглаживание временных рядов. Модели RNN и LSTM были обучены на основе алгоритма обратного распространения ошибки через время (BPTT) для точного прогноза параметров работы ГТД. Результаты показывают, что обе модели демонстрируют высокую точность прогноза, но модели RNN показывают лучшие результаты по большинству параметров. Для вибрационных параметров (VIB_N1FNT1, VIB_N1FNT2, VIB_N2FNT1 и VIB_N2FNT2) модели RNN показали более низкие значения RMSE и MAE, подтверждая их высокую точность. Для температурных параметров (EGT1 и EGT2) модели RNN также продемонстрировали более высокие показатели точности. В то же время модели LSTM показали лучшие результаты для некоторых параметров частоты вращения роторов низкого и высокого давления (N21 и N22). Выводы работы подчеркивают необходимость выбора подходящей модели в зависимости от характера данных и специфики параметров, которые необходимо прогнозировать. Будущие исследования могут быть направлены на разработку гибридных подходов, объединяющих преимущества обеих моделей для достижения наилучших результатов диагностики технического состояния авиационных ГТД.

Ключевые слова: безопасность полетов, диагностика авиационных газотурбинных двигателей, рекуррентные нейронные сети, длинно-краткосрочная память, прогноз параметров, вибрация, компрессор, турбина, алгоритм BPTT.

Для цитирования: Машошин О.Ф., Гусейнов Г., Засухин А.С. Методика диагностирования технического состояния авиационных газотурбинных двигателей с применением рекуррентных нейронных сетей (RNN) и длинно-краткосрочной памяти (LSTM) // Научный Вестник МГТУ ГА. 2024. Т. 27, № 6. С. 21–41. DOI: 10.26467/2079-0619-2024-27-6-21-41

Methodology for diagnosing the technical condition of aviation gas turbine engines using recurrent neural networks (RNN) and long short-term memory networks (LSTM)

O.F. Mashoshin¹, H. Huseynov¹, A.S. Zasukhin¹

¹Moscow State Technical University of Civil Aviation, Moscow, Russia

Abstract: This study presents a method for diagnosing the technical condition of aviation gas turbine engines (GTE) using recurrent neural networks (RNN) and long short-term memory networks (LSTM). The primary focus is on comparing the effectiveness of these models for forecasting key operating parameters of GTEs, such as vibrations, turbine-inlet temperatures, and rotor speeds of low and high pressure. The research involved thorough data cleaning and normalization, including handling missing values, normalization using Min-Max Scaling, outlier removal, data decorrelation, and time series smoothing. The RNN and LSTM models were trained using the backpropagation through time (BPTT) algorithm to accurately forecast GTE operating parameters. The results show that both models demonstrate high forecasting accuracy, but the RNN models perform better in most parameters.

For vibration parameters (VIB_N1FNT1, VIB_N1FNT2, VIB_N2FNT1, and VIB_N2FNT2), RNN models achieved lower RMSE and MAE values, confirming their higher accuracy. For temperature parameters (EGT1 and EGT2), RNN models also showed higher accuracy rates. Meanwhile, LSTM models achieved better results for some rotor speed parameters (N21 and N22). The findings emphasize the necessity of choosing the appropriate model based on the nature of data and the specifics of the parameters to be forecast. Future research may focus on developing hybrid approaches that combine the advantages of both models to achieve optimal results in diagnosing the technical condition of GTEs.

Key words: flight safety, gas turbine engine diagnostics, recurrent neural networks, long short-term memory, parameter forecasting, vibration, compressor, turbine, BPTT algorithm.

For citation: Mashoshin, O.F., Huseynov, H., Zasukhin, A.S. (2024). Methodology for diagnosing the technical condition of aviation gas turbine engines using recurrent neural networks (RNN) and long shortterm memory networks (LSTM). Civil Aviation High Technologies, vol. 27, no. 6, pp. 21–41. DOI: 10.26467/2079-0619-2024-27-6-21-41

Введение

Диагностика технического состояния газотурбинных двигателей (ГТД) является одной из ключевых задач в авиационной отрасли. Сложность конструкции, высокая стоимость, критичность работы ГТД и влияние на безопасность полетов требуют непрерывного контроля и своевременного выявления возможных неисправностей. Традиционные методы диагностики, основанные на анализе вибрационных и температурных показателей, а также на визуальном осмотре и измерении параметров, анализ параметров масляной системы, спектральный анализ масла, эндоскопия обладают рядом недостатков, включая субъективность оценок и высокую трудоемкость процесса. В условиях возрастающих требований к обеспечению безопасности полетов и надежности АТ необходимо искать новые, более эффективные подходы к диагностике.

Современные методы машинного обучения обладают новыми возможностями и преимуществами для повышения точности и оперативности диагностики ГТД. В частности, рекуррентные нейронные сети (RNN) и сети с длинно-краткосрочной памятью (LSTM) демонстрируют высокую эффективность в задачах анализа временных рядов и предсказания сложных динамических процессов [1–4].

Использование RNN и LSTM для диагностики ГТД имеет ряд преимуществ. Во-первых, эти модели способны автоматически извлекать и анализировать скрытые закономерности в больших объемах данных, что позволяет повысить точность прогнозирования и снизить вероятность ложных тревог. Во-

вторых, методы машинного обучения можно интегрировать в существующие системы мониторинга, обеспечивая непрерывный мониторинг и диагностику состояния двигателей. В-третьих, RNN и LSTM можно адаптировать к изменяющимся условиям эксплуатации, обеспечивая устойчивость и надежность диагностики в долгосрочной перспективе.

Целью настоящего исследования является разработка методики диагностирования технического состояния авиационного ГТД с использованием рекуррентных нейронных сетей и сетей с длинно-краткосрочной памятью. Для достижения этой цели были поставлены следующие задачи: сбор и предварительная обработка данных о работе ГТД (полученные с бортовых систем регистрации параметров), разработка алгоритмов обучения данных полетов параметров ГТД с применением моделей RNN и LSTM, оценка их эффективности на реальных данных и сравнение с традиционными методами диагностики в других работах.

Традиционные методы диагностики ГТД включают анализ вибраций, термографию, анализ температуры газа перед турбиной, отдельно выделим ультразвуковую дефектоскопию [5]. Эти методы позволяют выявлять неисправности на ранних стадиях и предупреждать о развитии серьезных повреждений. Однако их эффективность ограничена трудоемкостью и необходимостью высокой квалификации персонала. На рис. 1 представлена схема процесса диагностики ГТД, включающая этапы выявления, локализации и идентификации неисправностей и предложения мер по техническому обслуживанию [6].




Рис. 1. Традиционная схема процесса диагностики ГТД
Fig. 1. Conventional scheme of the GTE diagnostic process

Таким образом, применение методов машинного обучения, в частности рекуррентных нейронных сетей и сетей с длинно-краткосрочной памятью, открывает новые возможности для повышения безопасности и надежности авиационных систем. Данное исследование демонстрирует потенциал применения RNN- и LSTM-моделей для повышения точности диагностики технического состояния ГТД, что подтверждается улучшением показателей RMSE и MAE на 15–40 % по сравнению с традиционными методами [7, 8]. RMSE (Root Mean Square Error) – средне-квадратическое отклонение, MAE (Mean Absolute Error) – средняя абсолютная погрешность. Эти метрики используются для оценки точности прогнозирования моделей.

Меньшие значения RMSE и MAE указывают на более высокую точность модели.

Новизна данного исследования заключается в разработке комплексного подхода к диагностике ГТД, объединяющего преимущества моделей RNN и LSTM. В отличие от предыдущих работ [1, 3–5, 7, 9, 10], где эти модели применялись по отдельности, предлагаемый новый метод использует обе модели параллельно, что позволяет более точно прогнозировать различные параметры ГТД. Кроме того, мы вводим новшество визуализации результатов – расширенную карту распределения аномалий, которая позволяет одновременно отображать нормализованные величины аномалий и их суммарное значение во времени.

Предложенный метод визуализации – расширенная карта распределения аномалий – повышает эффективность диагностики ГТД за счет одновременного отображения нормализованных величин аномалий и их суммарного значения во времени, что позволяет выявлять сложные многофакторные неисправности и их динамику развития, улучшая интерпретируемость результатов и способствуя принятию более обоснованных решений по техническому обслуживанию.

Литературный обзор

Диагностика ГТД является одной из ключевых задач в обеспечении их надежности и долговечности. Существующие методы диагностики можно разделить на традиционные и современные, каждый из которых имеет свои преимущества и недостатки.

Традиционные методы диагностики включают вибрационный анализ, термографию, анализ параметров температуры перед турбиной, ультразвуковую дефектоскопию и другие методы неразрушающего контроля.

Вибрационный анализ как метод неразрушающего контроля является одним из наиболее распространенных методов диагностики ГТД, который позволяет выявлять механические неисправности, такие как дисбаланс, несоосность валов ротора и износ подшипников. Этот метод требует установки датчиков вибрации и достаточно сложного оборудования для анализа данных, что увеличивает стоимость диагностики.

Термография используется для обнаружения тепловых аномалий в работе ГТД. Этот метод позволяет выявлять проблемы с охлаждением и утечкой газоздушных потоков, но его применение ограничено поверхностным анализом и не позволяет обнаруживать внутренние дефекты.

Анализ температуры газа перед турбиной газов способствует оценке состояния камеры сгорания и других компонентов ГТД по составу и характеристикам выбросов. Этот метод требует регулярного отбора проб и лабо-

раторного анализа, что делает его менее оперативным и более затратным.

Ультразвуковая дефектоскопия как один из методов неразрушающего контроля применяется для обнаружения внутренних и подповерхностных дефектов в конструктивных элементах ГТД. Этот метод позволяет выявлять трещины и коррозию.

Методы неразрушающего контроля, включая магнитопорошковый контроль, контроль проникающими веществами, радиографический контроль и вихрековый контроль, позволяют обнаруживать поверхностные и внутренние дефекты без нарушения поверхностного слоя компонентов, но требуют специализированного оборудования и квалифицированного персонала.

Современные методы диагностики включают методы машинного обучения, такие как рекуррентные нейронные сети (RNN) и сети с длинно-краткосрочной памятью (LSTM), которые демонстрируют высокую эффективность в анализе временных рядов и предсказании динамических процессов.

RNN и LSTM позволяют учитывать нелинейные зависимости и временные корреляции в данных, что делает их идеальными для применения в задачах диагностики. Эти модели могут автоматически извлекать и анализировать скрытые закономерности в больших объемах данных, повышая точность предсказаний и снижая вероятность ложных обнаружений.

Сравнительный анализ методов диагностики ГТД представлен в табл. 1.

Научная проблема. Несмотря на значительные достижения в области традиционной диагностики ГТД, эти методы имеют ограничения, связанные с высокой стоимостью, трудоемкостью и необходимостью в высококвалифицированном персонале. Современные методы, такие как RNN и LSTM, показывают высокую эффективность, но требуют больших объемов данных и значительных вычислительных ресурсов. Основная научная проблема заключается в необходимости разработки методик, которые объединяют преимущества традиционных и современных ме-

Таблица 1
Table 1

Сравнительный анализ методов диагностики ГТД
Comparative analysis of diagnostic methods for GTE

Метод	Преимущества	Недостатки	Элементы конструкции	Эффективность, %	Источник
Вибрационный анализ	Высокая точность выявления механических неисправностей	Высокая стоимость установки и обслуживания датчиков, необходимость сложного спектрального анализа	Подшипники, роторы	85–90	[11]
Термография	Быстрое выявление тепловых аномалий	Ограничено поверхностным анализом, не обнаруживает внутренние дефекты	Система охлаждения дисков, лопаток	70–75	[12]
Анализ температур газа перед турбиной	Оценка состояния камеры сгорания	Необходимость регулярного отбора проб и лабораторного анализа	Камера сгорания	65–70	[13]
Ультразвуковая дефектоскопия	Обнаружение внутренних дефектов, высокая точность	Высокая квалификация персонала, специальное оборудование	Лопатки, диски, корпуса	90–95	[14]
Другие методы неразрушающего контроля	Без разрушения компонентов, высокая точность	Требуется специальное оборудование и квалифицированного персонала	Лопатки, диски (блиски), корпуса, сварные швы	85–95	[15]
RNN и LSTM	Учет нелинейных зависимостей и временных корреляций, автоматизация анализа	Необходимость большого объема данных для обучения, высокая вычислительная сложность	Все элементы	95–98	[9]

тодов, обеспечивая высокую точность и оперативность диагностики при оптимальных затратах и минимальных требованиях к ресурсам.

Методика исследования

Сбор и обработка данных являются ключевыми этапами в разработке методики диагностики технического состояния ГТД. Данные собираются с помощью встроенных датчиков, установленных на различных компонентах ГТД, которые регистрируют такие параметры, как температура, давление, вибрация, скорость вращения роторов. Все зарегистрированные параметры записываются в файлы формата Excel.

Процесс обработки данных включает следующие этапы.

1. Загрузка данных из файлов Excel с использованием библиотеки Pandas.
2. Очистка данных для обеспечения их качества и полноты.
3. Нормализация данных для приведения всех параметров к единой шкале.
4. Удаление выбросов с использованием статистического анализа.
5. Декорреляция данных методом главных компонент (PCA).
6. Сглаживание временных рядов с использованием скользящего среднего.

Для создания и обучения моделей на основе рекуррентных нейронных сетей (RNN) и сетей с длинно-краткосрочной памятью (LSTM) используются современные инстру-

менты и библиотеки, такие как Python, Pandas, NumPy, Scikit-learn, Keras и Matplotlib.

Обработка пропущенных значений была первым шагом в очистке и формировании статистических данных. Пропущенные значения в данных могут возникать по разным причинам, включая сбои в работе датчиков или ошибки при записи данных. Для обработки пропущенных значений мы использовали два подхода: замену на средние значения и линейную интерполяцию. Замена пропущенных значений на средние значения позволяет сохранить общую тенденцию данных без существенного искажения статистических характеристик:

$$x_i = \frac{1}{n} \sum_{j=1}^n x_{ij}, \quad (1)$$

где x_i – значение параметра для наблюдения i , x_{ij} – значение параметра для наблюдения j из набора данных n . В тех случаях, когда замена на среднее значение была недостаточно точной, мы использовали линейную интерполяцию для более точного восполнения пропущенных данных. Выражение для линейной интерполяции:

$$x(t) = x(t_0) + \frac{x(t_1) - x(t_0)}{t_1 - t_0} \cdot (t - t_0), \quad (2)$$

где $x(t)$ – значение параметра в момент времени t , $x(t_0)$ и $x(t_1)$ – значения параметра в моменты времени t_0 и t_1 соответственно.

После обработки пропущенных значений мы приступили к нормализации данных. Нормализация необходима для приведения всех параметров к единой шкале, что улучшает качество обучения моделей. Для этого использовали метод Min-MaxScaling, который преобразовывает значения параметров в диапазон от 0 до 1:

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}}, \quad (3)$$

где x – исходное значение параметра, $x_{\min}$ и $x_{\max}$ – минимальные и максимальные значения параметра соответственно, x' – нормализ-

ованное значение (1). Например, если минимальное значение температуры $T_{\min} = 200$ К, а максимальное значение $T_{\max} = 1600$ К, то при исходном значении температуры $T = 1000$ К нормализованное значение рассчитывается следующим образом:

$$T' = \frac{1000 - 200}{1600 - 200} = \frac{800}{1400} \approx 0,571.$$

Далее удалили выбросы из данных, так как они могут сильно исказить результаты анализа. Для обнаружения и удаления выбросов использовались методы статистического анализа, такие как анализ межквартильного размаха (IQR). Значения, выходящие за пределы $1,5 \cdot \text{IQR}$, считались выбросами.

Следующим шагом была декорреляция данных. Поскольку некоторые параметры могут быть сильно коррелированы друг с другом, для декорреляции данных использовался метод главных компонент (PCA). Этот метод позволяет уменьшить размерность данных, сохраняя при этом большую часть информации.

Для устранения шума в данных мы применили сглаживание временных рядов с использованием скользящего среднего:

$$S_t = \frac{1}{N} \sum_{i=t-N+1}^t x_i, \quad (4)$$

где S_t – значение сглаженного временного ряда в момент времени t , N – размер окна, скользящего среднего, x_i – значения исходного временного ряда.

После выполнения всех этих шагов данные были готовы для формирования временных рядов, которые необходимы для обучения моделей RNN и LSTM. Набор данных был разделен на обучающую и тестовую выборки в соотношении 67 на 33 % соответственно. Это позволило нам оценить производительность моделей на независимых данных и проверить их способность предсказывать будущие значения параметров и выявлять аномалии в работе ГТД.

Схема алгоритмов подготовки данных для создания и обучения моделей нейронной сети представлена на рис. 2.



Рис. 2. Схема алгоритмов подготовки данных для создания и обучения моделей нейронной сети
Fig. 2. Scheme of algorithms for data preparation for creation and training of neural network models

Методология и математическое описание сетей RNN и LSTM

Создание и обучение моделей рекуррентных нейронных сетей (RNN) и сетей с длинно-краткосрочной памятью (LSTM) требуют детального понимания их математических основ. В данном разделе рассмотрим основные уравнения и алгоритмы, используемые для построения этих моделей. Математиче-

ские основы RNN- и LSTM-моделей подробно описаны в работах [4, 8].

Рекуррентные нейронные сети (RNN). RNN моделируют временные зависимости в данных, используя скрытые состояния, которые обновляются на каждом шаге временного ряда. Пусть x_t обозначает входные данные на шаге t , h_t – скрытое состояние на шаге t , а y_t – выходные данные на шаге t .

Обновление скрытого состояния h_t происходит следующим образом:

$$h_t = \sigma(W_h \cdot h_{t-1} + W_x \cdot x_t + b_h), \quad (5)$$

где σ – нелинейная функция активации, например сигмоида или ReLU, W_h – веса скрытого слоя, W_x – веса входного слоя, b_h – смещение скрытого слоя.

В данной работе в качестве функции активации была использована сигмоидальная функция, описываемая уравнением (16).

Выходные данные y_t вычисляются как

$$y_t = W_y \cdot h_t + b_y, \quad (6)$$

где W_y – веса выходного слоя, b_y – смещение выходного слоя.

Обучая модель, мы стремимся уменьшить разницу между прогнозами и реальными значениями, например среднеквадратичную ошибку (MSE):

$$L = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2, \quad (7)$$

где y_i – истинное значение, $\hat{y}_i$ – предсказанное значение, N – количество обучающих наборов.

Сети с длинно-краткосрочной памятью (LSTM). LSTM-ячейки решают проблему затухающих градиентов, характерную для традиционных RNN, за счет введения механизмов забывания, входа и выхода, которые управляют потоками информации через ячейку.

Основные компоненты LSTM-ячейки включают в себя следующее.

1. Вектор забывания f_t :

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f), \quad (8)$$

где W_f – веса для вектора забывания, b_f – смещение для вектора забывания, σ – сигмоида.

2. Вектор входа i_t :

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i), \quad (9)$$

где W_i – веса для вектора входа, b_i – смещение для вектора входа.

3. Создание нового кандидата состояния памяти $\tilde{C}_t$:

$$\tilde{C}_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C), \quad (10)$$

где W_C – веса для состояния памяти, b_C – смещение для состояния памяти, $\tanh$ – гиперболический тангенс.

4. Обновление состояния памяти C_t :

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t, \quad (11)$$

где $C_{(t-1)}$ – предыдущее состояние памяти.

5. Вектор выхода o_t :

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o), \quad (12)$$

где W_o – веса для вектора выхода, b_o – смещение для вектора выхода.

6. Обновление скрытого состояния h_t :

$$h_t = o_t \cdot \tanh(C_t). \quad (13)$$

Таким образом, LSTM-ячейка использует векторы забывания, входа и выхода для управления состоянием памяти и скрытым состоянием, позволяет эффективно обрабатывать длинные временные зависимости.

Обучение моделей. Процесс обучения моделей RNN и LSTM включает в себя обновление весов для минимизации функции потерь. Обучение выполняется с использованием алгоритма обратного распространения ошибки через время (BPTT), который учитывает временные зависимости [16].

Применение алгоритма BPTT для обучения моделей RNN и LSTM

1. Вычисление градиентов.

Для каждого временного шага вычисляются градиенты функции потерь по весам. Пусть $\mathcal{L}$ – функция потерь, тогда градиенты для весов входного слоя W_x и весов скрытого слоя W_h в RNN вычисляются следующим образом:

$$\frac{\partial \mathcal{L}}{\partial W_x} = \sum_{t=1}^T \frac{\partial \mathcal{L}}{\partial h_t} \cdot \frac{\partial h_t}{\partial W_x},$$

$$\frac{\partial \mathcal{L}}{\partial W_h} = \sum_{t=1}^T \frac{\partial \mathcal{L}}{\partial h_t} \cdot \frac{\partial h_t}{\partial W_h},$$

где T – количество временных шагов.

2. Обновление весов.

Весовые коэффициенты обновляются с использованием градиентного спуска. Пусть η – скорость обучения, тогда обновление весов выполняется по следующим уравнениям:

$$W_x = W_x - \eta \cdot \frac{\partial \mathcal{L}}{\partial W_x}, \quad (14)$$

$$W_h = W_h - \eta \cdot \frac{\partial \mathcal{L}}{\partial W_h}. \quad (15)$$

Для LSTM обновление весов выполняется аналогично, с учетом всех весов W_f , W_i , W_c , W_o и соответствующих градиентов.

Управление потоком информации в LSTM

Важной частью обучения LSTM является управление потоком информации через механизмы забывания и входа:

а) обновление состояния памяти:

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \bar{C}_t,$$

где f_t – вектор забывания, i_t – вектор входа, C_t – новая информация для добавления в состояние памяти (11);

б) обновление скрытого состояния:

$$h_t = o_t \cdot \tanh(C_t),$$

где o_t – вектор выхода, C_t – текущее состояние памяти (13).

Эти механизмы позволяют LSTM эффективно обрабатывать долгосрочные зависимости в данных, избегая проблемы затухающих градиентов.

Доработанные алгоритмы обучения полетных данных параметров авиационных ГТД с применением моделей RNN и LSTM на основе BPTT

Процесс обучения моделей RNN и LSTM включает использование алгоритма обратного распространения ошибки через время

(BPTT). Этот метод позволяет эффективно учитывать временные зависимости в данных и обновлять веса модели для минимизации функции потерь. В этом разделе подробно рассмотрены доработанные алгоритмы обучения данных полетных параметров ГТД с использованием BPTT.

Алгоритм обратного распространения ошибки через время (BPTT)

BPTT расширяет стандартный алгоритм обратного распространения ошибки, учитывая временную структуру данных. Обучение включает вычисление градиентов функции потерь по весам на каждом временном шаге и их обновление для минимизации функции потерь:

а) выбор функции активации:

в алгоритмах RNN и LSTM важным элементом является функция активации. Мы используем сигмоидальную функцию активации σ для входных и выходных ворот (всех диапазонов) и гиперболический тангенс $\tanh$ для обновления состояния.

$$\sigma(x) = \frac{1}{1+e^{-x}}, \quad (16)$$

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}; \quad (17)$$

б) обновление градиентов:

градиенты функции потерь по весам вычисляются для каждого временного шага. Для RNN градиенты для весов входного слоя W_x и весов скрытого слоя W_h вычисляются следующим образом:

$$\frac{\partial \mathcal{L}}{\partial W_x} = \sum_{t=1}^T \frac{\partial \mathcal{L}}{\partial h_t} \cdot \frac{\partial h_t}{\partial W_x}, \quad (18)$$

$$\frac{\partial \Omega}{\partial W_h} = \sum_{t=1}^T \frac{\partial \Omega}{\partial h_t} \cdot \frac{\partial h_t}{\partial W_h}. \quad (19)$$

Для LSTM вычисление градиентов включает в себя дополнительные параметры для всех диапазонов:

$$\frac{\partial \Omega}{\partial W_f} = \sum_{t=1}^T \frac{\partial \Omega}{\partial f_t} \cdot \frac{\partial f_t}{\partial W_f}, \quad (20)$$

$$\frac{\partial \Omega}{\partial w_i} = \sum_{t=1}^T \frac{\partial \Omega}{\partial i_t} \cdot \frac{\partial i_t}{\partial w_i}, \quad (21)$$

$$\frac{\partial \Omega}{\partial w_o} = \sum_{t=1}^T \frac{\partial \Omega}{\partial o_t} \cdot \frac{\partial o_t}{\partial w_o}, \quad (22)$$

$$\frac{\partial \Omega}{\partial w_c} = \sum_{t=1}^T \frac{\partial \Omega}{\partial c_t} \cdot \frac{\partial c_t}{\partial w_c}; \quad (23)$$

в) обновление весов:

весовые коэффициенты обновляются с использованием градиентного спуска. Пусть η – скорость обучения, тогда обновление весов выполняется по следующим уравнениям:

$$W_x = W_x - \eta \cdot \frac{\partial \Omega}{\partial w_x}, \quad (24)$$

$$W_h = W_h - \eta \cdot \frac{\partial \Omega}{\partial w_h}. \quad (25)$$

Для LSTM обновление весов выполняется аналогично:

$$W_f = W_f - \eta \cdot \frac{\partial \Omega}{\partial w_f}, \quad (26)$$

$$W_i = W_i - \eta \cdot \frac{\partial \Omega}{\partial w_i}, \quad (27)$$

$$W_o = W_o - \eta \cdot \frac{\partial \Omega}{\partial w_o}, \quad (28)$$

$$W_c = W_c - \eta \cdot \frac{\partial \Omega}{\partial w_c}; \quad (29)$$

г) полная формула потерь для LSTM:

суммирование всех потерь для разных входов в LSTM дает полную формулу потерь

$$\Omega = \sum_{t=1}^T [\Omega_f + \Omega_i + \Omega_o + \Omega_c],$$

где Ω_f , Ω_i , Ω_o , Ω_c – потери для забывания входа, выхода и состояния памяти соответственно.

Уравнения 1–30 являются основой примененной в этой работе модели для обучения моделей RNN и LSTM на данных полетных параметров ГТД с использованием алгоритма BPTT. Доработанные алгоритмы обеспечивают высокую точность и надежность моде-

лей при прогнозировании и выявлении аномалий в работе газотурбинных двигателей.

Применение данных моделей позволяет не только диагностировать текущее состояние, но и прогнозировать будущие неисправности на основе идентифицированных тенденций и аномалий, что значительно повышает эффективность технического обслуживания и предотвращение аварийных событий. В разделе «Реализация и результаты» представлены результаты проведенного расчетно-вычислительного эксперимента на основе параметров ГТД самолета A320, такие как EGT1 и EGT2 (IAEEGTLPTXITTEMPSYS. 1 и SYS. 2). Эти параметры температуры газа перед турбиной позволяют выявить аномалии в процессах сгорания топливно-воздушной смеси, что критично для обеспечения безопасности полетов [10]. Анализ частоты вращения роторов низкого и высокого давления (N1, N2) дает возможность оценить общую эффективность и состояние механических компонентов двигателя. Вибрационные показатели (VIB_N1FNT1, VIB_N1FNT2, VIB_N2FNT1, VIB_N2FNT2) используются для диагностики состояния подшипников и роторов. Результаты эксперимента подтвердили высокую точность предсказаний моделей LSTM и RNN в выявлении и классификации неисправностей, что демонстрирует перспективность данного подхода для раннего обнаружения и предотвращения серьезных поломок в эксплуатации авиационных газотурбинных двигателей.

Реализация и результаты

Для цели и задач данного исследования разработано программное обеспечение (ПО) (рис. 3) для анализа данных двигателя, включающее интуитивный интерфейс на PyQt5. ПО позволяет загружать данные полета из Excel, выбирать столбцы для анализа, настраивать параметры моделей RNN и LSTM, такие как количество эпох, размер батча и lookback. Данное ПО было разработано в среде PyCharm на языке Python с использованием библиотек PyQt5 для создания

Анализатор данных двигателя

Загрузка файла

Загрузить файл Excel

Выберите лист:

Выбор столбцов

Выберите столбцы для анализа:

Конфигурация модели

Тип модели: RNN

Количество эпох: 20

Размер батча: 1

Look back: 10

Доля обучающей выборки: 0,67

Параметры анализа

☒ Построить основной график

☒ Построить график аномалий

☒ Построить карту распределения аномалий

☒ Построить расширенную карту аномалий

Провести анализ


Рис. 3. Интерфейс анализатора полетных данных авиадвигателя

Fig. 3. Aircraft engine flight data analyzer interface


графического интерфейса, pandas для обработки данных и Keras для реализации нейросетевых моделей. Общий алгоритм работы программы включает следующие этапы: 1) загрузка данных из Excel-файла; 2) предварительная обработка данных; 3) обучение моделей RNN и LSTM; 4) прогнозирование параметров; 5) визуализация результатов. Ограничения применения программы связаны с необходимостью наличия достаточного объема исторических данных для обучения моделей (рекомендуется не менее 1 000 полетных циклов). Валидация ПО проводилась путем сравнения результатов прогнозирования с реальными данными на тестовой выборке, не участвовавшей в обучении моделей. После анализа автоматически генерируются графики прогнозов, аномалий и карты распределения аномалий. Также вычисляются

метрики точности (RMSE, MAE, R2 и др.) для каждого параметра. Результаты представлены на рис. 4, 5 и в дополнительных материалах к данной статье, размещенных на сайте издательства журнала¹.

¹ Машошин О.Ф., Гусейнов Г., Засухин А.С. Результаты анализа и прогнозирования технического состояния двигателя воздушного судна по температурным параметрам и по параметрам частот вращения ротора [Электронный ресурс] // Научный Вестник МГТУ ГА. DOI: 10.26467/2079-0619-2024-27-6-img (дата обращения: 16.10.2024).



a



б






Рис. 4. Анализ и прогнозирование технического состояния по вибрационным параметрам (VIB_N1FNT1, VIB_N1FNT2, VIB_N2FNT1, VIB_N2FNT2) ГТД с применением доработанной модели RNN:
a – динамика временных рядов вибрационных параметров; *б* – анализ временных рядов вибрационных характеристик; *в* – тепловая карта распределения вибраций во времени; *г* – тепловая карта временных изменений вибраций

Fig. 4. Analysis and forecasting of technical condition by vibration parameters (VIB_N1FNT1, VIB_N1FNT2, VIB_N2FNT1, VIB_N2FNT2) of GTE using the modified RNN model:
a – dynamics of time series of vibration parameters; *б* – analysis of time series of vibration characteristics; *в* – heat map of vibration distribution over time; *г* – heat map of temporal changes in vibrations



a



б




Рис. 5. Анализ и прогнозирование технического состояния по вибрационным параметрам (VIB_N1FNT1, VIB_N1FNT2, VIB_N2FNT1, VIB_N2FNT2) ГТД с применением доработанной модели LSTM:
a – динамика вибрационных параметров (VIB_N1FNT1, VIB_N1FNT2, VIB_N2FNT1, VIB_N2FNT2) во времени;
б – график отклонений прогнозов вибрационных параметров; *в* – тепловая карта распределения вибраций (VIB_N1FNT1); *г* – тепловая карта временных изменений вибраций (VIB_N2FNT2)
Fig. 5. Analysis and forecasting of technical condition based on vibration parameters (VIB_N1FNT1, VIB_N1FNT2, VIB_N2FNT1, VIB_N2FNT2) of GTE using the modified LSTM model:
a – dynamics of vibration parameters (VIB_N1FNT1, VIB_N1FNT2, VIB_N2FNT1, VIB_N2FNT2) over time; *б* – graph of deviations in the forecasts of vibration parameters; *в* – heat map of vibration distribution (VIB_N1FNT1); *г* – heat map of temporal changes in vibrations (VIB_N2FNT2)

Таблица 2
Table 2

Эффективность моделей RNN и LSTM
Performance of RNN and LSTM models

Параметр	Модель	RMSE	MAE	R ²
Вибрации (VIB_N1FNT1)	RNN	0,0458	0,0198	0,9801
Вибрации (VIB_N1FNT1)	LSTM	0,0531	0,0317	0,9732
Вибрации (VIB_N1FNT2)	RNN	0,0888	0,0542	0,9958
Вибрации (VIB_N1FNT2)	LSTM	0,1488	0,1127	0,9883
Вибрации (VIB_N2FNT1)	RNN	0,0457	0,0199	0,9516
Вибрации (VIB_N2FNT1)	LSTM	0,0491	0,0243	0,9442
Вибрации (VIB_N2FNT2)	RNN	0,0413	0,0242	0,9340
Вибрации (VIB_N2FNT2)	LSTM	0,0384	0,0178	0,9427
Температура (EGT1)	RNN	3,4186	1,5747	0,9951
Температура (EGT1)	LSTM	4,0480	2,7927	0,9932
Температура (EGT2)	RNN	3,8570	2,8511	0,9931
Температура (EGT2)	LSTM	4,1418	3,0956	0,9920
Обороты (N11)	RNN	1,7743	0,4207	0,9912
Обороты (N11)	LSTM	1,7291	0,5483	0,9917
Обороты (N12)	RNN	1,4202	0,3903	0,9944
Обороты (N12)	LSTM	1,5643	0,4788	0,9932
Обороты (N21)	RNN	2,9701	0,3328	0,9849
Обороты (N21)	LSTM	2,2666	0,5455	0,9912
Обороты (N22)	RNN	1,7390	0,4600	0,9949
Обороты (N22)	LSTM	1,3346	0,4241	0,9970

Результаты, представленные в табл. 2, были получены на основе анализа данных 20 двигателей CFM56-5B4, эксплуатируемых на самолетах A320, за период 2 года в эксплуатации. Общий объем данных составил около 15 000 полетных циклов. Значения RMSE и MAE рассчитывались путем сравнения прогнозов моделей с реальными значениями параметров на тестовой выборке, составляющей 30 % от общего объема данных.

Сравнение с традиционными методами диагностики

Для оценки эффективности предложенного подхода мы сравнили его результаты с

традиционными методами диагностики ГТД, такими как спектральный анализ вибраций и анализ тренда параметров. Результаты сравнения представлены в табл. 3.

Сравнение с традиционными методами, представленное в табл. 3, проводилось на основе анализа данных пяти двигателей за период 6 месяцев (около 1 000 полетных циклов). В качестве традиционных методов использовались спектральный анализ вибраций и анализ трендов параметров, выполняемые штатными средствами технического обслуживания авиакомпании.

Как видно из таблицы, предложенный метод превосходит традиционные подходы по точности обнаружения неисправностей и ско-

Таблица 3
Table 3

Сравнение эффективности методов диагностики ГТД [14, 15]
Comparison of the effectiveness of gas turbine diagnostic methods [14, 15]

Метод	Точность обнаружения неисправностей, %	Время обнаружения, мин	Возможность прогнозирования
Предложенный метод	95	< 1	Да
Спектральный анализ	85	5–10	Нет
Анализ тренда параметров	80	> 10	Ограниченная

рости анализа. Кроме того, он обладает возможностью прогнозирования будущих состояний ГТД, что отсутствует у большинства традиционных методов. Это позволяет не только выявлять текущие проблемы, но и предотвращать потенциальные неисправности.

Обсуждение результатов

Результаты анализа эффективности моделей RNN и LSTM показывают, что обе модели демонстрируют высокую точность предсказаний для различных параметров работы ГТД. Тем не менее модели LSTM показывают немного более высокую точность по сравнению с моделями RNN для большинства параметров.

Для вибрационных параметров (VIB_N1FNT1, VIB_N1FNT2, VIB_N2FNT1 и VIB_N2FNT2) модели RNN показали более низкие значения RMSE и MAE по сравнению с моделями LSTM, что свидетельствует об их большей точности в задачах предсказания вибраций. Высокие значения коэффициента детерминации (R^2) для обеих моделей подтверждают их способность адекватно моделировать вибрационные характеристики [7].

Для температурных параметров (EGT1 и EGT2) модели RNN также показали лучшие результаты по сравнению с моделями LSTM с более низкими значениями RMSE и MAE. Высокие значения R^2 для обеих моделей свидетельствуют о том, что они способны точно предсказывать температуру газа перед турбиной, учитывая временные зависимости.

Для параметров частоты вращения роторов низкого и высокого давления (N11, N12, N21 и N22) результаты несколько варьируются. Модели RNN показали лучшие результаты для параметра N12, в то время как модели LSTM были более точными для параметров N21 и N22. Это может быть связано с различиями в характере данных для этих параметров и необходимостью более сложного учета временных зависимостей.

Результаты подтверждают, что обе модели, RNN и LSTM, являются эффективными инструментами для предсказания параметров работы ГТД. В тех случаях, когда модели RNN показали лучшие результаты, они в среднем на 15,44 % точнее моделей LSTM по показателю RMSE. RNN продемонстрировали особенно высокую эффективность в прогнозировании вибрационных и температурных параметров, с улучшением точности до 40 % в некоторых случаях.

Эти результаты свидетельствуют о том, что выбор модели для диагностики ГТД должен учитывать характер и особенности данных для каждого конкретного параметра. В дальнейшем исследовании, возможно, стоит рассмотреть гибридные подходы, объединяющие преимущества обеих моделей, для достижения наилучших результатов диагностики [17].

Практическая значимость разработанной методики диагностирования технического состояния ГТД с применением моделей RNN и LSTM заключается в возможности ее интеграции в существующие системы мониторинга и технического обслуживания авиацион-

ных двигателей. Например, внедрение данной методики в процесс технического обслуживания парка самолетов A320 с двигателями CFM56-5B4 позволило бы снизить количество незапланированных технических обслуживаний на 15–20 % за счет раннего выявления потенциальных неисправностей. Это в свою очередь может привести к сокращению времени пребывания ВС в состоянии простоя и снижению эксплуатационных расходов авиапредприятия. По предварительным оценкам, экономический эффект от внедрения методики может составить до 500 000 долларов США в год на парк из 50 самолетов за счет оптимизации процессов технического обслуживания и предотвращения дорогостоящих ремонтов [5]. Кроме того, повышение точности диагностики технического состояния ГТД напрямую влияет на безопасность полетов, что является ключевым фактором в отрасли. Предложенную методику можно адаптировать для различных типов ГТД, что расширяет сферу ее практического применения в авиации.

Несмотря на высокую эффективность предложенного метода, следует отметить его ограничения. Во-первых, метод требует значительного массива статистических данных для обучения моделей, что может быть проблематично для новых или редко используемых типов ГТД. Во-вторых, точность прогнозов может снижаться при резких изменениях режимов работы двигателя или внешних условий, не представленных в обучающей выборке. В-третьих, интерпретация результатов, особенно в случае расхождений между прогнозами RNN и LSTM, может требовать экспертной оценки. Дальнейшие исследования могут быть направлены на разработку методов адаптивного обучения моделей и интеграцию экспертных знаний в процесс интерпретации результатов.

Заключение

В данном исследовании была разработана и протестирована методика диагностики технического состояния ГТД с использованием рекуррентных нейронных сетей (RNN) и се-

тей с длинно-краткосрочной памятью (LSTM). Проведенные исследования и расчетно-вычислительные эксперименты показали, что обе модели демонстрируют высокую точность прогнозирования технического состояния по ключевым параметрам его работы, таким как вибрации, температура газов перед турбиной и частота вращения роторов низкого и высокого давления.

Модели RNN и LSTM продемонстрировали высокую эффективность, при этом RNN показали лучшие результаты для вибрационных и температурных характеристик, а LSTM – для некоторых параметров частоты вращения роторов. Выбор оптимальной модели зависит от конкретного анализируемого параметра ГТД. В то же время модели LSTM продемонстрировали высокую точность для некоторых параметров частоты вращения роторов низкого и высокого давления, что свидетельствует о возможности их эффективного применения в задачах, требующих более сложного учета временных зависимостей.

Полученные результаты подчеркивают необходимость выбора подходящей модели в зависимости от характера данных и специфики параметров, которые необходимо прогнозировать. В будущем целесообразно рассмотреть разработку гибридных подходов, объединяющих преимущества моделей RNN и LSTM, для достижения наилучших результатов диагностики технического состояния ГТД. Настоящее исследование вносит вклад в развитие методик диагностики и предлагает новые подходы к решению задач обеспечения надежности и безопасности авиационных систем ГТД.

Список литературы

1. Fentaye A.D., Zaccaria V., Kyprianidis K. Aircraft engine performance monitoring and diagnostics based on deep convolutional neural networks [Электронный ресурс] // Machines. 2021. Vol. 9, iss. 12. ID: 337. DOI: 10.3390/machines9120337 (дата обращения: 27.02.2024).
2. Al-Tekreeti W.K.F., Kashyzadeh K.R., Ghorbani S. Advancements in gas turbine fault

detection: a machine learning approach based on the temporal convolutional network-autoencoder model [Электронный ресурс] // Applied Sciences. 2024. Vol. 14, iss. 11. ID: 4551. DOI: 10.3390/app14114551 (дата обращения: 27.02.2024).

3. **Berghout T.** ProgNet: A transferable deep network for aircraft engine damage propagation prognosis under real flight conditions / T. Berghout, M.-D. Mouss, L.-H. Mouss, M. Benbouzid [Электронный ресурс] // Aerospace. 2023. Vol. 10, iss. 1. ID: 10. DOI: 10.3390/aerospace10010010 (дата обращения: 27.02.2024).

4. **Hochreiter S., Schmidhuber J.** Long short-term memory // Neural computation. 1997. Vol. 9, iss. 8. Pp. 1735–1780. DOI: 10.1162/neco.1997.9.8.1735

5. **Zhao J., Li Y.-G., Sampath S.** Convolutional neural network denoising autoencoders for intelligent aircraft engine gas path health signal noise filtering [Электронный ресурс] // Journal of Engineering for Gas Turbines and Power. 2023. Vol. 145, iss. 6. ID: 061013. DOI: 10.1115/1.4056128 (дата обращения: 27.02.2024).

6. **Garg S., Simon D.** Challenges in aircraft engine gas path health management [Электронный ресурс] // Proceedings of the Tutorial on Aircraft Engine Control and Gas Path Health Management, Cleveland, OH, USA, 2012. 64 p. URL: <https://ntrs.nasa.gov/api/citations/20150009565/downloads/20150009565.pdf> (дата обращения: 15.02.2024).

7. **Mohammadi R.** Fault diagnosis of gas turbine engines by using dynamic neural networks / R. Mohammadi, E. Naderi, K. Khorasani, S. Hashtrudi-Zad // 2011 IEEE International Conference on Quality and Reliability. Bangkok, Thailand, 2011. Pp. 25–30. DOI: 10.1109/ICQR.2011.6031675

8. **Goodfellow I., Bengio Y., Courville A.** Deep learning. The MIT Press, 2016. 800 p.

9. **Clifton D.** Condition monitoring of gas-turbine engines [Электронный ресурс] // Transfer Report. Department of Engineering Science, University of Oxford, 2006. 60 p. URL: <https://www.robots.ox.ac.uk/~davidc/pubs/transfer.pdf> (дата обращения: 27.02.2024).

10. **Upadhyay A.** A deep-learning-based approach for aircraft engine defect detection / A. Upadhyay, J. Li, S. King, S. Addepalli [Электронный ресурс] // Machines. 2023. Vol. 11, iss. 2. ID: 192. DOI: 10.3390/machines11020192 (дата обращения: 27.02.2024).

11. **Zhou D.** Fault diagnosis of gas turbine based on partly interpretable convolutional neural networks / D. Zhou, Q. Yao, H. Wu, S. Ma, H. Zhang [Электронный ресурс] // Energy. 2020. Vol. 200. ID: 117467. DOI: 10.1016/j.energy.2020.117467 (дата обращения: 27.02.2024).

12. **Falsetti C., Sisti M., Beard P.F.** Infra-red thermography and calibration techniques for gas turbine applications: A review [Электронный ресурс] // Infrared Physics & Technology. 2021. Vol. 113. ID: 103574. DOI: 10.1016/j.infrared.2020.103574 (дата обращения: 27.02.2024).

13. **Zhao F.** Gas turbine exhaust system health management based on recurrent neural networks / F. Zhao, L. Chen, T. Xia, Z. Ye, Y. Zheng // Procedia CIRP. 2019. Vol. 83, no. 12. Pp. 630–635. DOI: 10.1016/j.procir.2019.04.122

14. **Pitkänen J.** NDT methods for revealing anomalies and defects in gas turbine blades / J. Pitkänen, T. Hakkarainen, H. Jeskanen, P. Kuusinen, K. Lahdenperä, P. Särkiniemi [Электронный ресурс] // 15th World Conference on Non-destructive Testing. Italy, Roma, 15–21 October 2000. URL: <https://www.ndt.net/article/wcndt00/papers/idn629/idn629.htm> (дата обращения: 27.02.2024).

15. **Loboda I.** Neural networks for gas turbine diagnosis [Электронный ресурс] // Artificial Neural Networks-Models and Applications, 2016. DOI: 10.5772/63107 (дата обращения: 27.02.2024).

16. **Pineda F.J.** Generalization of back-propagation to recurrent neural networks [Электронный ресурс] // Physical Review Letters. 1987. Vol. 59, iss. 19. ID: 2229. DOI: 10.1103/PhysRevLett.59.2229 (дата обращения: 27.02.2024).

17. **Панков Е.А., Чайка Н.Ф.** Возможности спектральных методов для диагностики авиационных двигателей // Интерэкспо Гео-Сибирь. 2016. № 9. С. 8–13.

References

1. Fentaye, A.D., Zaccaria, V., Kyprianidis, K. (2021). Aircraft engine performance monitoring and diagnostics based on deep convolutional neural networks. *Machines*, vol. 9, issue 12, ID: 337. DOI: 10.3390/machines9120337 (accessed: 27.02.2024).
2. Al-Tekreiti, W.K.F., Kashyzadeh, K.R., Ghorbani, S. (2024). Advancements in gas turbine fault detection: a machine learning approach based on the temporal convolutional network-autoencoder model. *Applied Sciences*, vol. 14, issue 11, ID: 4551. DOI: 10.3390/app14114551 (accessed: 27.02.2024).
3. Berghout, T., Mouss, M.-D., Mouss, L.-H., Benbouzid, M. (2023). ProgNet: A transferable deep network for aircraft engine damage propagation prognosis under real flight conditions. *Aerospace*, vol. 10, issue 1, ID: 10. DOI: 10.3390/aerospace10010010 (accessed: 27.02.2024).
4. Hochreiter, S., Schmidhuber, J. (1997). Long short-term memory. *Neural computation*, vol. 9, issue 8, pp. 1735–1780. DOI: 10.1162/neco.1997.9.8.1735
5. Zhao, J., Li, Y.-G., Sampath, S. (2023). Convolutional neural network denoising autoencoders for intelligent aircraft engine gas path health signal noise filtering. *Journal of Engineering for Gas Turbines and Power*, vol. 145, issue 6, ID: 061013. DOI: 10.1115/1.4056128 (accessed: 27.02.2024).
6. Garg, S., Simon, D. (2012). Challenges in aircraft engine gas path health management. In: *Proceedings of the Tutorial on Aircraft Engine Control and Gas Path Health Management*, Cleveland, OH, USA, 64 p. Available at: <https://ntrs.nasa.gov/api/citations/20150009565/download/20150009565.pdf> (accessed: 15.02.2024).
7. Mohammadi, R., Naderi, E., Khorasani, K., Hashtrudi-Zad, S. (2011). Fault diagnosis of gas turbine engines by using dynamic neural networks. *2011 IEEE International Conference on Quality and Reliability*. Bangkok, Thailand, pp. 25–30. DOI: 10.1109/ICQR.2011.6031675
8. Goodfellow, I., Bengio, Y., Courville, A. (2016). *Deep learning*. The MIT Press, 800 p.
9. Clifton, D. (2006). Condition monitoring of gas-turbine engines. *Transfer Report*, Department of Engineering Science, University of Oxford, 60 p. Available at: <https://www.robots.ox.ac.uk/~davidc/pubs/transfer.pdf> (accessed: 27.02.2024).
10. Upadhyay, A., Li, J., King, S., Addepalli, S. (2023). A deep-learning-based approach for aircraft engine defect detection. *Machines*, vol. 11, issue 2, ID: 192. DOI: 10.3390/machines11020192 (accessed: 27.02.2024).
11. Zhou, D., Yao, Q., Wu, H., Ma, S., Zhang, H. (2020). Fault diagnosis of gas turbine based on partly interpretable convolutional neural networks. *Energy*, vol. 200, ID: 117467. DOI: 10.1016/j.energy.2020.117467 (accessed: 27.02.2024).
12. Falsetti, C., Sisti, M., Beard, P.F. (2021). Infrared thermography and calibration techniques for gas turbine applications: A review. *Infrared Physics & Technology*, vol. 113, ID: 103574. DOI: 10.1016/j.infrared.2020.103574 (accessed: 27.02.2024).
13. Zhao, F., Chen, L., Xia, T., Ye, Z., Zheng, Y. (2019). Gas turbine exhaust system health management based on recurrent neural networks. *Procedia CIRP*, vol. 83, no. 12, pp. 630–635. DOI: 10.1016/j.procir.2019.04.122
14. Pitkänen, J., Hakkarainen, T., Jeskanen, H., Kuusinen, P., Lahdenperä, K., Särkinen, P. (2000). NDT methods for revealing anomalies and defects in gas turbine blades. In: *15th World Conference on Nondestructive Testing*, Italy, Roma, 15–21 October. Available at: <https://www.ndt.net/article/wcndt00/papers/idn629/idn629.htm> (accessed: 27.02.2024).
15. Loboda, I. (2016). Neural networks for gas turbine diagnosis. In book: *Artificial Neural Networks-Models and Applications*. DOI: 10.5772/63107 (accessed: 27.02.2024).
16. Pineda, F.J. (1987). Generalization of back-propagation to recurrent neural networks. *Physical Review Letters*, vol. 59, issue 19, ID: 2229. DOI: 10.1103/PhysRevLett.59.2229 (accessed: 27.02.2024).
17. Pankov, E.A., Chayka, N.F. (2016). The possibilities of spectral methods for aircraft engines diagnosis. *Interexpo Geo-Siberia*, no. 9, pp. 8–13. (in Russian)

Сведения об авторах

Машошин Олег Федорович, доктор технических наук, профессор, заведующий кафедрой двигателей летательных аппаратов МГТУ ГА, o.mashoshin@mstuca.ru.

Гусейнов Гусейн, аспирант кафедры двигателей летательных аппаратов МГТУ ГА, khuseyn.21@gmail.com.

Засухин Александр Сергеевич, начальник учебно-тренажерного центра, старший преподаватель кафедры двигателей летательных аппаратов МГТУ ГА, a.zasuhin@mstuca.ru.

Information about the authors

Oleg F. Mashoshin, Doctor of Technical Sciences, Professor, The Head of the Aircraft Engines Chair, Moscow State Technical University of Civil Aviation, o.mashoshin@mstuca.aero.

Huseyn Huseynov, Postgraduate Student, Aircraft Engines Chair, Moscow State Technical University of Civil Aviation, khuseyn.21@gmail.com.

Aleksandr S. Zasukhin, The Head of the Training and Simulator Center, Senior Lecturer, Aircraft Engines Chair, Moscow State Technical University of Civil Aviation, a.zasuhin@mstuca.ru.

Поступила в редакцию	12.08.2024	Received	12.08.2024
Одобрена после рецензирования	30.10.2024	Approved after reviewing	30.10.2024
Принята в печать	28.11.2024	Accepted for publication	28.11.2024