

18. Chaitra Y., Dinesh R., Gopalakrishna M., Prakash B.A. Deep-CNNLT: Text Localization from Natural Scene Images Using Deep Convolution Neural Network with Transfer Learning, *Arabian Journal for Science and Engineering*, 2021, No. 47 (9), pp. 9629-9640.
19. He T., Tian Z., Huang W., Shen C., Qiao Y., Sun C. An End-to-End TextSpotter with Explicit Alignment and Attention, *IEEE Conference on Computer Vision and Pattern Recognition*, 2018, pp. 5020-5029.
20. Bulatov K.B. A method to reduce errors of string recognition based on combination of several recognition results with per-character alternatives, *Vestnik Yuzhno-Ural'skogo gosudarstvennogo universiteta. Seriya: Matematicheskoe modelirovanie i programmirovaniye* [Bulletin of the South Ural State University. Series: Mathematical modeling and programming], 2019, Vol. 12, No. 3, pp. 74-88. DOI: 10.14529/mmp190307.
21. Panishchev V.S., Trufanov M.I., Dobroserdov O.G., Khomyakov O.O. Raspoznavanie simvol'noy informatsii dlya avtomatizatsii proizvodstvennykh protsessov [Recognition of symbolic information for automation of production processes], *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta* [News of the South-Western State University], 2021, No. 1, pp. 122-137.

Статью рекомендовал к опубликованию д.т.н., профессор В.В. Курейчик.

Панищев Владимир Славиевич – Юго-Западный государственный университет; e-mail: gskunk@yandex.ru; г. Курск, Россия; кафедра вычислительной техники; к.т.н.; доцент; с.н.с.

Хомяков Олег Олегович – e-mail: homyakov46rus@yandex.ru; кафедра вычислительной техники; аспирант.

Титов Дмитрий Витальевич – e-mail: amazing2004@inbox.ru; д.т.н.; доцент; профессор кафедры вычислительной техники.

Егоров Сергей Иванович – e-mail: sie58@mail.ru; д.т.н.; доцент; профессор кафедры вычислительной техники.

Panishchev Vladimir Slavievich – South-West State University; e-mail: gskunk@yandex.ru; Kursk, Russia; the department of computer science; cand. of eng. sc., associate professor; senior researcher.

Khomyakov Oleg Olegovich – e-mail: homyakov46rus@yandex.ru; the department of computer science; postgraduate.

Titov Dmitry Vitalievich – e-mail: amazing2004@inbox.ru; dr. of tech. sc., associate professor of the department of computer science.

Egorov Sergey Ivanovich – e-mail: sie58@mail.ru; dr. of eng. sc., associate professor; professor of the department of computer science.

УДК 004.9

DOI 10.18522/2311-3103-2023-4-65-74

К.С. Задиран

НОВЫЙ МЕТОД ПРОГНОЗИРОВАНИЯ ОСТАТОЧНОГО РЕСУРСА ОБОРУДОВАНИЯ ДЛЯ ВЫСОКОЧАСТОТНЫХ ДАННЫХ С НЕОДНОРОДНОЙ ДЛИТЕЛЬНОСТЬЮ РАБОЧИХ ЦИКЛОВ

Достижения в машиностроении позволяют создавать более совершенное и эффективное оборудование, однако при этом повышается его сложность и требования к управлению его жизненным циклом, техническим обслуживанием. К этому прибавляются требования по надежности и доступности, которые также создают дополнительные испытания при управлении жизненным циклом. Существуют различные стратегии планирования технического обслуживания. Среди них наиболее перспективной является предиктивная стратегия, основанная на прогнозировании остаточного ресурса оборудования. Существующие методы прогнозирования остаточного ресурса оборудования фокусируются на

применении исторических данных, агрегированных по рабочим циклам, при этом отсутствуют широко распространенные методы для прогнозирования по непрерывным данным, в том числе высокочастотным, получаемым с оборудования и содержащим рабочие циклы различной длительности и данные, записанные во время простоя оборудования. Для решения этой проблемы предлагается метод прогнозирования остаточного ресурса с выделением в исходных данных рабочих циклов и агрегированием их значений в одномерные векторы с целью дальнейшего использования для обучения модели прогнозирования. Результаты демонстрируют успешную применимость предложенного метода – в комбинации с моделью прогнозирования XGBoost удается достичь точности на данных, полученных с газотурбинного двигателя, со значением средней квадратической ошибки 14.02 и средней ошибкой 10.71.

Турбинные двигатели, управление жизненным циклом промышленного оборудования, остаточный ресурс оборудования, машинное обучение.

K.S. Zadiran

A NEW METHOD FOR PREDICTING THE REMAINING EQUIPMENT LIFE FOR HIGH-FREQUENCY DATA WITH NON-UNIFORM DUTY CYCLES

Advances in mechanical engineering make it possible to create more advanced and efficient equipment, but at the same time, its complexity and the requirements for managing its life cycle and maintenance increase. Requirements for reliability and availability also create additional challenges to life cycle management. There are various maintenance planning strategies. Among them, the most promising is the predictive strategy based on forecasting the remaining useful life of the equipment. Existing methods for predicting the remaining useful life of equipment focus on the use of historical data aggregated by work cycles, while there are no widely used methods for forecasting using continuous data, including high-frequency data, received from equipment and containing work cycles of various durations and data recorded during downtime. To solve this problem, a method for predicting the remaining useful life is proposed with the determination of work cycles in the initial data and the aggregation of their values into one-dimensional vectors for the purpose of further use for training the forecasting model. The results demonstrate the successful applicability of the proposed method - in combination with the XGBoost forecast model, it is possible to achieve accuracy on data obtained from a gas turbine engine with a root mean square error of 14.02 and mean average error of 10.71.

Turbine engines; industrial equipment lifecycle management; remaining useful life; machine learning.

Введение. Управление жизненным циклом промышленного оборудования является важной составляющей процесса эксплуатации [1]. От его эффективности зависит надежность, доступность, общая стоимость эксплуатации [2, 3]. Управление жизненным циклом включает работы по техническому обслуживанию и ремонту оборудования [3]. Сложность и стоимость ремонтных работ современного оборудования, а также условия эксплуатации и требования надежности и высокой доступности, в свою очередь, создают дополнительные испытания в планировании работ [4–6].

Существуют различные стратегии управления жизненным циклом, которые подразделяются на реактивные и проактивные [7, 8]. Наиболее перспективной среди проактивных стратегий является предиктивная [9], схема которой приведена на рис. 1. Эта стратегия основана на прогнозировании изменения состояния оборудования и его остаточного ресурса для оптимального планирования технического обслуживания.

Один из параметров, на основе прогнозирования которых строится предиктивная стратегия управления жизненным циклом, это – остаточный ресурс оборудования (Remaining Useful Life – RUL) [11]. Данный параметр обозначает величину ресурса компонента или системы оборудования от текущего момента до следующего отказа оборудования [12]. Его значение определяется, как интервал между текущим моментом времени t и моментом отказа t_{EOL} , и записывается в виде:

$$RUL_t = t_{EOL} - t. \quad (1)$$

Значение RUL коррелирует со значением остаточного ресурса, или, состоянием оборудования [12], и снижается одновременно с ним. Данная зависимость проиллюстрирована на рис. 2.

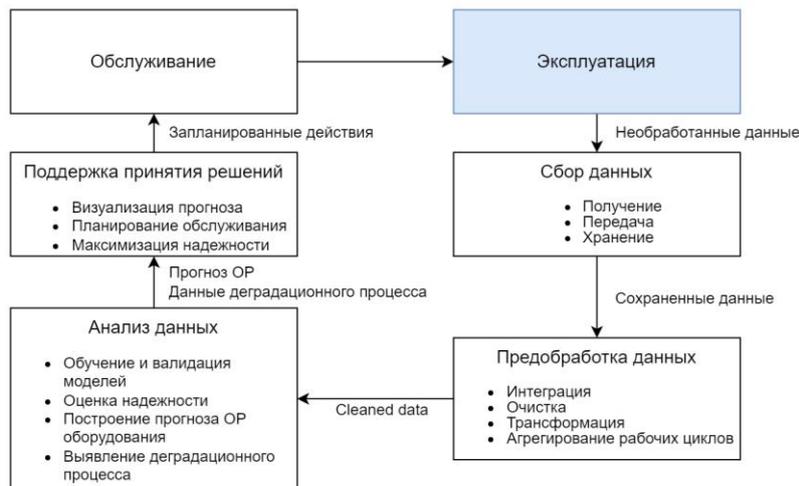


Рис. 1. Схема предиктивной стратегии управления жизненным циклом оборудования [10]

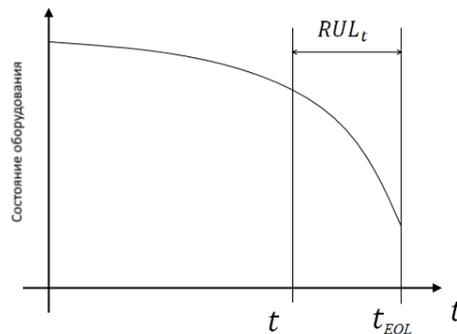


Рис. 2. Зависимость между моментом отказа и остаточным ресурсом [9]

Прогнозирование RUL широко исследовано, включает использование, как классических методов, так и нейросетевых моделей и методов глубокого обучения и других архитектур, а также их различных комбинаций [9, 13]. В работах исследованы классические методы прогнозирования: SVM [14, 15], деревья решений и градиентного бустинга XGBoost [16], k-ближайших соседей [9], байесовских методов [17]

и других. Нейросетевые модели и методы глубокого обучения включают применение таких моделей, как сверточные нейросети CNN [18, 19], LSTM [9, 20, 21], рекуррентные сети RNN [22], глубокие сети доверия [23] и других. Разработаны методы выявления стадий деградации оборудования при прогнозировании RUL [10, 14, 24].

Большинство методов прогнозирования RUL для объектов промышленного оборудования используют в качестве входных данных исторические значения параметров, агрегированных по рабочим циклам [9, 15, 24, 25]. Рабочим циклом считается период от запуска оборудования до его отключения. В данном агрегированном представлении данные об одном рабочем цикле представлены в виде вектора значений длиной n , где n – количество измеряемых параметров оборудования, где каждому параметру соответствует одно значение [25].

В случае, когда для построения прогноза используются данные, которые не были агрегированы, точность методов прогнозирования в отдельных применениях снижается, и они не могут быть использованы для построения прогноза [26]. Не агрегированные данные о рабочем цикле представляют собой многомерный временной ряд с количеством измерений n , длина которого изменяется в зависимости от длительности конкретного цикла.

Для решения проблемы неоднородности длительностей рабочих циклов и точности прогнозирования предлагается новый метод, включающий выделение рабочих циклов в исторических данных, их преобразование в набор агрегированных значений, где каждому из циклов соответствует одномерный вектор значений. Исследование проведено на примере данных газотурбинных двигателей.

Описание метода. Для прогнозирования остаточного ресурса оборудования (RUL) предлагается новый метод, который использует агрегирование данных рабочих циклов и применение существующей модели прогнозирования.

Данное решение позволяет использовать данные, не прошедшие предварительную обработку и содержащие информацию о рабочих циклах переменной длительности. Помимо этого, применение описываемого метода позволит увеличить горизонт прогнозирования и объем доступных данных, которые могут быть использованы для обучения модели в сравнении с использованием только существующих методов. Также, метод позволяет применить существующие модели прогнозирования с высокой точностью на данных, на которых ранее не удавалось построить точный прогноз RUL [26].

Входные данные – временные ряды, непрерывные исторические записи с n датчиков промышленного оборудования за период с высокой частотой (1 запись в секунду и более).

Выходные данные – построенный прогноз RUL.

Предлагаемый метод состоит из шести шагов. Схема метода приведена на рис. 3.

Первый шаг метода – предварительное агрегирование высокочастотных данных до 1 измерения в минуту. Применяемая функция агрегирования – среднее значение. Основная цель – повышение производительности следующих шагов. Также этот шаг способствует отсеиванию аномалий из данных.

На втором шаге производится выделение рабочих циклов из непрерывного потока данных. Для этого применяется алгоритм, схема которого приведена на рис. 4. Выполняется разметка стадий рабочего цикла. Сначала для каждого параметра входных данных X_i^j , где j – номер параметра, i – номер записи во временном ряду, вычисляется его разность с предыдущим

$$\Delta = X_i^j - X_{i-1}^j$$

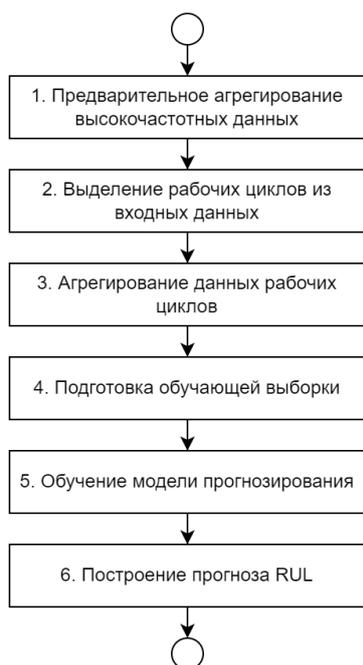


Рис. 3. Схема предлагаемого метода



Рис. 4. Схема алгоритма выделения рабочих циклов

Промежутков, в котором значения постоянно увеличиваются, помечается как начало рабочего цикла – прогрев. Промежутков, в котором значения параметров оборудования постоянно снижаются, считается окончанием рабочего цикла – остыванием. Идущие подряд промежутки прогрева и остываний объединяются в один для обработки возможных прерываний в прогреве/остывании. Короткие отдельно стоящие промежутки отбрасываются, как аномалии. Пороговое значение применяется для обработки флуктуации параметров из-за влияния внешней среды и устанавливается для каждого набора данных индивидуально. Пример визуализации размеченных стадий на данных приведен на рис. 5. Промежуток между началом и окончанием – работа оборудования под нагрузкой – основная часть рабочего цикла. Все остальные данные – простой оборудования.

Далее выделяются данные рабочих циклов, которые будут использоваться в дальнейших шагах. Для этого из размеченных стадий выделяются и сохраняются данные периодов работы под нагрузкой. Все остальные данные отбрасываются.

На третьем шаге производится агрегирование данных для каждого цикла. Для каждого параметра в цикле вычисляется три значения: среднее, усредненное максимальное и усредненное минимальное.

Усредненное максимальное значение вычисляется как среднее верхнего дециля значений. Усредненное минимальное значение вычисляется таким же образом для нижнего дециля значений параметра рабочего цикла.

В результате для каждого цикла строится описывающий его вектор значений длиной $3n$ по количеству измеряемых параметров входных данных n и усредненных минимальных и максимальных значений для каждого из них. Это устраняет неоднородность в размерности данных рабочих циклов и позволяет в дальнейшем применять существующие модели прогнозирования.

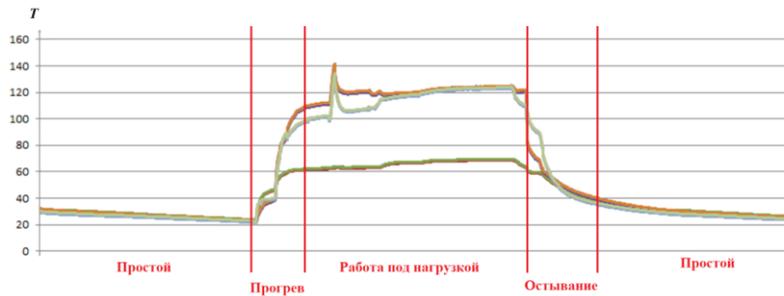


Рис. 5. Пример стадий рабочих циклов

На четвертом шаге осуществляется подготовка данных для использования в обучении модели прогнозирования. Соответствие данных показывается формулой 2:

$$F(X_i) = Y_i, \quad (2)$$

где X_i – входное значение, Y_i – выходное значение, F – функция модели прогнозирования.

Выходные данные X_i для точки i формируются как значения RUL для i -того цикла.

Входные данные X_i для точки i группируются с использованием метода скользящего окна. В этой функции берется w входных значений X_k^j , $j \in [1; n]$, $k \in [i - w; i]$, которые группируются в матрицу и затем разворачиваются в одномерный массив путем соединения всех строк матрицы, как проиллюстрировано в формуле 3:

$$X_i = \begin{vmatrix} X_{w-i}^1 & \dots & X_i^1 \\ \vdots & \ddots & \vdots \\ X_{w-i}^n & \dots & X_i^n \end{vmatrix} = |X_{w-i}^1; \dots; X_i^1; \dots; X_{w-i}^n; \dots; X_i^n|. \quad (3)$$

При этом, для моделей прогнозирования, поддерживающих двумерные входные данные, таких, как сверточная нейронная сеть, разворачивание в одномерный массив может быть пропущено.

На пятом шаге производится обучение модели прогнозирования. Для устранения возможных неточностей применяется метод кросс-валидации.

На шестом шаге производится построение прогноза остаточного ресурса оборудования с использованием существующих моделей.

Результаты. Для проверки метода использовались данные с газотурбинного двигателя за два года использования. Пример данных приведен на рис. 6.

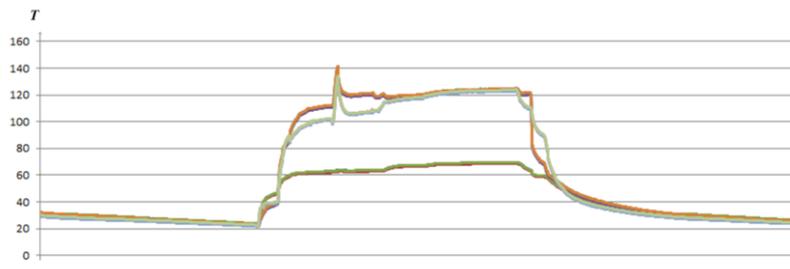


Рис. 6. Пример рабочего цикла в исходных данных

Из данных были выделено 116 рабочих циклов. После преобразования данных о циклах в обучающую выборку было получено 110 записей с $w = 7$. Пример преобразованных данных приведен на рис. 7.

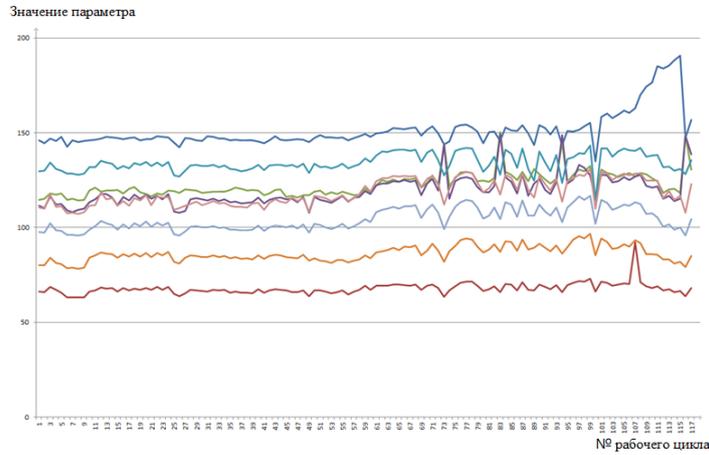


Рис. 7. Пример агрегированных данных

Для проверки метода были выбраны следующие модели: линейная регрессия, Catboost, XGBoost. Модели, основанные на нейронных сетях, не применялись из-за недостаточного объема данных.

Результаты проверки моделей приведены в табл. 1. Сравнение производилось с использованием метрик RMSE и MAE [27].

Таблица 1

Результаты прогнозирования RUL для моделей

Модель прогнозирования	RMSE	MAE
Линейная регрессия	38.11	21.01
Catboost	16.81	11.14
XGBoost	14.02	10.71

Графики с прогнозными значениями приведены на рис. 8 для линейной регрессии и на рис. 9 для XGBoost.

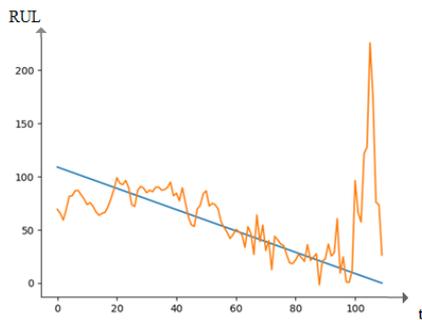


Рис. 8. Результат построения прогноза с применением линейной регрессии

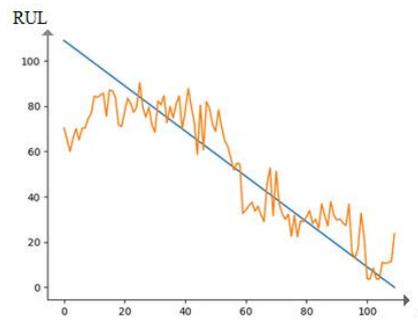


Рис. 9. Результат построения прогноза с применением XGBoost

На этих графиках синим цветом отмечены реальные значения, оранжевым – полученные в результате прогнозирования. Скачок полученных с использованием линейной регрессии прогнозных значений в конце интервала можно объяснить изменением во входных данных, не распознанном моделью прогнозирования.

Заключение. В данной работе предложен и рассмотрен новый метод прогнозирования остаточного ресурса оборудования. Данный метод предложен для ситуаций с не агрегированными историческими данными, содержащими рабочие циклы переменной длительности, для обучения модели, в которых нет возможности построить точный прогноз RUL существующими способами. Для решения этой проблемы предложен метод выделения рабочих циклов из данных и их агрегирования с последующим прогнозированием. Предложенный метод в отдельных сценариях повышает точность прогнозирования остаточного ресурса оборудования и позволяет построить прогноз для данных, на которых ранее не удавалось получить точные значения RUL с использованием существующих методов.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. *Куприяновский В.П., Намиот Д.Е., Дрожжинов В.И., Куприяновская Ю.В., Иванов М.О.* Интернет вещей на промышленных предприятиях // *International Journal of Open Information Technologies*. – 2016. – № 12. – С. 156-161.
2. *Гунина И.А., Шкарупета Е.В., Решетов В.В.* Прорывное технологическое развитие промышленных комплексов в условиях цифровой трансформации // *Инновационные кластеры цифровой экономики: теория и практика*. – 2018. – С. 535-554.
3. *Лысенко С.В., Тен Э.В.* Об оценке остаточного ресурса башенных кранов // *Проблемы современной науки и образования*. – 2016. – № 1. – С. 98-102.
4. *Manasis C., Assimakis N., Vikias V., Ktena A., Stamatielos T.* Power Generation Prediction of an Open Cycle Gas Turbine Using Kalman Filter // *Energies*. – 2020. – No. 13. – P. 6692.
5. *Антоненко И.Н., Крюков И.Э.* Информационные системы и практики ТОиР: этапы развития // *Автоматизация*. – 2011. – № 1. – С. 37-44.
6. *Chen X., Yan R., Liu Y.* Wind turbine condition monitoring and fault diagnosis in China // *IEEE Instrumentation & Measurement Magazine*. – 2016. – No. 19. – P. 22-28.
7. *Susto G.A., Schirru A., Pampuri S., McLoone S., Beghi A.* Machine learning for predictive maintenance: A multiple classifier approach // *IEEE Transactions on Industrial Informatics*. – 2014. – No. 11. – P. 812-820.
8. *Ажмухамедов И.М., Гостюнин Ю.А.* Выбор стратегии технического обслуживания и ремонта оборудования сетей связи на предприятиях нефтегазового комплекса // *Инженерный вестник Дона*. – 2017. – № 2 (45). – С. 1-10.
9. *Сай Ван Квонг, Щербаков М.В.* Метод прогнозирования остаточного ресурса на основе обработки данных многообъектных сложных систем // *Прикаспийский журнал: управление и высокие технологии*. – 2019. – № 1 (45). – С. 33-44.
10. *Zadran K., Shcherbakov M.* New Method of Degradation Process Identification for Reliability-Centered Maintenance of Energy Equipment // *Energies*. – 2023. – No. 16. – P. 575.
11. *Cheng J.C., Chen W., Chen K., Wang Q.* Data-driven predictive maintenance planning framework for MEP components based on BIM and IoT using machine learning algorithms // *Automation in Construction*. – 2020. – No. 112. – P. 1-21.
12. *Xiongzi C., Jinsong Y., Diyin T., Yingxun W.* Remaining useful life prognostic estimation for aircraft subsystems or components: A review // *10th IEEE International Conference on Electronic Measurement & Instruments (ICEMI)*. – 2011. – P. 92-94.
13. *Zhao J., Gao C., Tang T., Xiao X., Luo M., Yuan B.* Overview of Equipment Health State Estimation and Remaining Life Prediction Methods // *Machines*. – 2022. – No. 10. – P. 422.
14. *Yan M., Wang X., Wang B., Chang M., Muhammad I.* Bearing remaining useful life prediction using support vector machine and hybrid degradation tracking model // *ISA transactions*. – 2020. – No. 98. – P. 471-482.
15. *Nieto P.G., Garcia-Gonzalo E., Lasheras F.S., De Cos Juez F.J.* Hybrid PSO-SVM-based method for forecasting of the remaining useful life for aircraft engines and evaluation of its reliability // *Reliability Engineering & System Safety*. – 2015. – No. 138. – P. 219-231.

16. Patil S., Patil A., Handikherkar V., Desai S., Phalle V.M., Kazi F.S. Remaining Useful Life (RUL) Prediction of Rolling Element Bearing Using Random Forest and Gradient Boosting Technique // ASME 2018 International Mechanical Engineering Congress and Exposition. – 2018. – P. 1-7.
17. Ng S.S., Xing Y., Tsui K.L. A naive Bayes model for robust remaining useful life prediction of lithium-ion battery // Applied Energy. – 2014. – No. 118. – P. 114-123.
18. Babu G.S., Zhao P., Li X.L. Deep convolutional neural network based regression approach for estimation of remaining useful life // In Proceedings of the International Conference on Database Systems for Advanced Applications (Dallas, TX, USA, 16–19 April 2016). – 2016. – P. 214-228.
19. Li X., Ding Q., Sun J. Remaining useful life estimation in prognostics using deep convolution neural networks // Reliability Engineering & System Safety. – 2018. – No. 172. – P. 1-11.
20. Che-Sheng H., Jehn-Ruey J. Remaining useful life estimation using long short-term memory deep // In 2018 IEEE International Conference on Applied System Invention (ICASI) (Chiba, Japan). – IEEE, 2018. – P. 58-61.
21. Sagheer A., Kotb M. Unsupervised pre-training of a Deep LSTM-based Stacked Autoencoder for Multivariate time Series forecasting problems // Scientific Reports. – 2019. – No. 9. – P. 1-16.
22. Zhang Y., Xin Y., Liu Z.W., Chi M., Ma G. Health status assessment and remaining useful life prediction of aero-engine based on BiGRU and MMoE // Reliability Engineering & System Safety. – 2022. – No. 220. – P. 108-123.
23. Deutsch J., He D. Using deep learning-based approach to predict remaining useful life of rotating components // IEEE Transactions on Systems, Man, and Cybernetics: Systems. – 2017. – No. 48. – P. 11-20.
24. Wang H.K., Cheng Y., Song K. Remaining Useful Life Estimation of Aircraft Engines Using a Joint Deep Learning Model Based on TCNN and Transformer // Computational Intelligence and Neuroscience. – 2021. – No. 2021. – P. 1-14.
25. NASA Turbofan Jet Engine Data Set. – Режим доступа: <https://www.kaggle.com/datasets/behrad3d/nasa-staps> (дата обращения: 01.04.2023).
26. Задиран К.С., Щербаков М.В., Сай Ван Квонг. Прогнозирование остаточного ресурса оборудования в условиях малой выборки данных // Управление большими системами. – 2023. – № 102. – С. 99-113.
27. Shcherbakov M.V. A Survey of Forecast Error Measures // World Applied Sciences Journal (WASJ). – 2013. – No. 24. – P. 171-176.

REFERENCES

1. Kupriyanovskiy V.P., Namiot D.E., Drozhzhinov V.I., Kupriyanovskaya Yu.V., Ivanov M.O. Internet veshchey na promyshlennykh predpriyatiyakh [Internet of things in industrial enterprises], *International Journal of Open Information Technologies*, 2016, No. 12, pp. 156-161.
2. Gunina I.A., SHkarupeta E.V., Reshetov V.V. Proryvnoye tekhnologicheskoye razvitiye promyshlennykh kompleksov v usloviyakh tsifrovoy transformatsii [Breakthrough technological development of industrial complexes in the context of digital transformation], *Innovatsionnye klasteri tsifrovoy ekonomiki: teoriya i praktika* [Innovative clusters of the digital economy: theory and practice], 2018, pp. 535-554.
3. Lysenko S.V., Ten E.V. Ob otsenke ostatochnogo resursa bashennykh kranov [On assessing the residual life of tower cranes], *Problemy sovremennoy nauki i obrazovaniya* [Problems of modern science and education], 2016, No. 1, pp. 98-102.
4. Manasis C., Assimakis N., Vikias V., Ktena A., Stamatelos T. Power Generation Prediction of an Open Cycle Gas Turbine Using Kalman Filter, *Energies*, 2020, No. 13, pp. 6692.
5. Antonenko I.N., Kryukov I.E. Informatsionnye sistemy i praktiki TOiR: etapy razvitiya [Information systems and maintenance and repair practices: stages of development], *Avtomatizatsiya* [Automation], 2011, No. 1, pp. 37-44.
6. Chen X., Yan R., Liu Y. Wind turbine condition monitoring and fault diagnosis in China, *IEEE Instrumentation & Measurement Magazine*, 2016, No. 19, pp. 22-28.
7. Susto G.A., Schirru A., Pampuri S., McLoone S., Beghi A. Machine learning for predictive maintenance: A multiple classifier approach, *IEEE Transactions on Industrial Informatics*, 2014, No. 11, pp. 812-820.
8. Azhmukhamedov I.M., Gostyunin Yu.A. Vybor strategii tekhnicheskogo obsluzhivaniya i remonta oborudovaniya setey svyazi na predpriyatiyakh neftegazovogo kompleksa [Choice of strategy for maintenance and repair of communication network equipment at oil and gas enterprises], *Inzhenernyy vestnik Dona* [Engineering Bulletin of the Don], 2017, No. 2 (45), pp. 1-10.

9. Say Van Kvong, Shcherbakov M.V. Metod prognozirovaniya ostatochnogo resursa na osnove obrabotki dannykh mnogoob"ektnykh slozhnykh sistem [A method for forecasting residual life based on data processing of multi-object complex systems], *Prikaspiyskiy zhurnal: upravlenie i vysokie tekhnologii* [Caspian Journal: management and high technologies], 2019, No. 1 (45), pp. 33-44.
10. Zadiran K., Shcherbakov M. New Method of Degradation Process Identification for Reliability-Centered Maintenance of Energy Equipment, *Energies*, 2023, No. 16, pp. 575.
11. Cheng J.C., Chen W., Chen K., Wang Q. Data-driven predictive maintenance planning framework for MEP components based on BIM and IoT using machine learning algorithms, *Automation in Construction*, 2020, No. 112, pp. 1-21.
12. Xiongzi C., Jinsong Y., Diyin T. Yingxun W. Remaining useful life prognostic estimation for aircraft subsystems or components: A review, *10th IEEE International Conference on Electronic Measurement & Instruments (ICEMI)*, 2011, pp. 92-94.
13. Zhao J., Gao C., Tang T., Xiao X., Luo M., Yuan B. Overview of Equipment Health State Estimation and Remaining Life Prediction Methods, *Machines*, 2022, No. 10, pp. 422.
14. Yan M., Wang X., Wang B., Chang M., Muhammad I. Bearing remaining useful life prediction using support vector machine and hybrid degradation tracking model, *ISA transactions*, 2020, No. 98, pp. 471-482.
15. Nieto P.G., Garcia-Gonzalo E., Lasheras F.S., De Cos Juez F.J. Hybrid PSO-SVM-based method for forecasting of the remaining useful life for aircraft engines and evaluation of its reliability, *Reliability Engineering & System Safety*, 2015, No. 138, pp. 219-231.
16. Patil S., Patil A., Handikherkar V., Desai S., Phalle V.M., Kazi F.S. Remaining Useful Life (RUL) Prediction of Rolling Element Bearing Using Random Forest and Gradient Boosting Technique, *ASME 2018 International Mechanical Engineering Congress and Exposition*, 2018, pp. 1-7.
17. Ng S.S., Xing Y., Tsui K.L. A naive Bayes model for robust remaining useful life prediction of lithium-ion battery, *Applied Energy*, 2014, No. 118, pp. 114-123.
18. Babu G.S., Zhao P., Li X.L. Deep convolutional neural network based regression approach for estimation of remaining useful life, *In Proceedings of the International Conference on Database Systems for Advanced Applications (Dallas, TX, USA, 16-19 April 2016)*, 2016, pp. 214-228.
19. Li X., Ding Q., Sun J. Remaining useful life estimation in prognostics using deep convolution neural networks, *Reliability Engineering & System Safety*, 2018, No. 172, pp. 1-11.
20. Che-Sheng H., Jehn-Ruey J. Remaining useful life estimation using long short-term memory deep, *In 2018 IEEE International Conference on Applied System Invention (ICASI) (Chiba, Japan)*. IEEE, 2018, pp. 58-61.
21. Sagheer A., Kotb M. Unsupervised pre-training of a Deep LSTM-based Stacked Autoencoder for Multivariate time Series forecasting problems, *Scientific Reports*, 2019, No. 9, pp. 1-16.
22. Zhang Y., Xin Y., Liu Z.W., Chi M., Ma G. Health status assessment and remaining useful life prediction of aero-engine based on BiGRU and MMoE, *Reliability Engineering & System Safety*, 2022, No. 220, pp. 108-123.
23. Deutsch J., He D. Using deep learning-based approach to predict remaining useful life of rotating components, *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 2017, No. 48, pp. 11-20.
24. Wang H.K., Cheng Y., Song K. Remaining Useful Life Estimation of Aircraft Engines Using a Joint Deep Learning Model Based on TCNN and Transformer, *Computational Intelligence and Neuroscience*, 2021, No. 2021, pp. 1-14.
25. NASA Turbofan Jet Engine Data Set. Available at: <https://www.kaggle.com/datasets/behrad3d/nasa-cmaps> (accessed 01 April 2023).
26. Zadiran K.S., Shcherbakov M.V., Say Van Kvong. Prognozirovanie ostatochnogo resursa oborudovaniya v usloviyakh maloy vyborke dannykh [Forecasting the residual life of equipment in conditions of a small data sample], *Upravlenie bol'shimi sistemami* [Management of large systems], 2023, No. 102, pp. 99-113.
27. Shcherbakov M.V. A Survey of Forecast Error Measures, *World Applied Sciences Journal (WASJ)*, 2013, No. 24, pp. 171-176.

Статью рекомендовал к опубликованию д.т.н. Ю.А. Кравченко.

Задирин Константин Сергеевич – Волгоградский государственный технический университет; e-mail: konstantin.zadiran@gmail.com; г. Волгоград, Россия; аспирант.

Zadiran Konstantin Sergeevich – Volgograd State Technical University; e-mail: konstantin.zadiran@gmail.com; Volgograd, Russia; postgraduate student.