

Киргизбаев Данияр Мусаевич

Руководитель группы КИП, отдел Техобслуживания,

Тенгизшевройл, Алматы, Казахстан

МЕТОД ПРОГНОЗИРОВАНИЯ ОСТАТОЧНОГО РЕСУРСА СРЕДСТВ КИП и А С ДИНАМИЧЕСКОЙ ОЦЕНКОЙ РИСКА И RAG- ПОДДЕРЖКОЙ ПРИНЯТИЯ РЕШЕНИЙ

Аннотация. Предложен метод предиктивного обслуживания средств контрольно-измерительных приборов и автоматики, основанный на совместном использовании прогнозирования остаточного ресурса, динамической оценки риска отказа и поиска по специализированной инженерной базе знаний. Для прогнозирования Remaining Useful Life формализовано представление эксплуатационных данных в виде последовательностей диагностических и технологических параметров с учетом режима работы и истории обслуживания. Предусмотрен выбор модели между Random Forest, градиентным бустингом и LSTM по значениям MAE, RMSE и направлению ошибки прогноза. Для учета неопределенности точечная оценка остаточного ресурса дополняется прогнозным интервалом. На основе его нижней границы, текущего отклонения технического состояния и критичности оборудования предложен динамический индекс риска, определяющий срочность инженерного реагирования. Для информационной поддержки специалиста сформирован принцип построения RAG-модуля, выполняющего поиск по техническим руководствам, регламентам обслуживания, сведениям об отказах и истории выполненных работ. Генеративная модель используется только для подготовки документально подтвержденной рекомендации и не изменяет рассчитанные значения остаточного ресурса и риска. Процедура выбора модели проверена на открытом наборе NASA C-MAPSS FD001. В рассматриваемом примере Random Forest показал минимальное значение RMSE 17,09 цикла и наибольшее R^2 0,8181, тогда как Gradient Boosting обеспечил минимальное MAE 12,05 цикла.

Полученные результаты показывают необходимость выбора алгоритма для конкретного класса оборудования по совокупности показателей точности и характера прогнозной ошибки.

Ключевые слова: КИПиА; предиктивное обслуживание; остаточный ресурс; Remaining Useful Life; машинное обучение; динамический риск; Random Forest; LSTM; Retrieval-Augmented Generation; RAG.

REMAINING USEFUL LIFE PREDICTION METHOD FOR INSTRUMENTATION AND AUTOMATION ASSETS WITH DYNAMIC RISK ASSESSMENT AND RAG-ASSISTED DECISION SUPPORT

Name Surname

academic degree, position

full organization name, city, Russian Federation

ORCID: ...

Abstract. A predictive maintenance method for instrumentation and automation equipment is proposed, based on the combined use of Remaining Useful Life prediction, dynamic failure risk assessment, and retrieval from a specialized engineering knowledge base. For Remaining Useful Life prediction, operational data are formalized as sequences of diagnostic and process parameters, taking into account operating conditions and maintenance history. The method provides for model selection among Random Forest, Gradient Boosting, and LSTM based on MAE, RMSE, and the direction of prediction error. To account for uncertainty, the point estimate of Remaining Useful Life is supplemented with a prediction interval. Based on its lower bound, the current deviation in equipment condition, and equipment criticality, a dynamic risk index is proposed to determine the urgency of engineering response. To support engineering decision-making, a principle for constructing a RAG module is developed, enabling retrieval from technical manuals, maintenance regulations, failure records, and maintenance history. The generative model is used solely to prepare a recommendation supported by documented evidence and does not modify the calculated Remaining Useful Life or risk values. The model-selection procedure is validated using the open NASA C-MAPSS FD001 dataset. In the

examined case, Random Forest achieved the lowest RMSE of 17.09 cycles and the highest R^2 of 0.8181, whereas Gradient Boosting provided the lowest MAE of 12.05 cycles. The results demonstrate that the prediction algorithm should be selected for a specific equipment class based on a combination of accuracy metrics and the characteristics of prediction errors.

Keywords: instrumentation and automation; predictive maintenance; remaining useful life; machine learning; dynamic risk assessment; Random Forest; LSTM; retrieval-augmented generation; RAG; decision support.

Введение

Техническое обслуживание средств КИПиА традиционно опирается на регламентные интервалы, калибровку и пороговый контроль. Приведенный порядок технического обслуживания в целом необходим, однако слабо учитывает фактический режим эксплуатации, индивидуальную деградацию и историю работ; помимо этого, дополнительными ограничениями предиктивной аналитики остаются качество данных и дефицит репрезентативных выборок [1]. Методы машинного обучения позволяют оценивать будущее состояние оборудования. Например, на данных производственных линий показана применимость Random Forest, XGBoost и других регрессионных алгоритмов к прогнозированию Remaining Useful Life (RUL), причем в одном промышленном исследовании модель позволила предупредить около 42% остановов исследуемых линий [2].

Однако для средств КИПиА одинаковое отклонение сигнала имеет разную значимость в зависимости от назначения прибора, резервирования и последствий ошибочного измерения. Поэтому инженерному решению необходимы прогноз RUL, его неопределенность, текущее отклонение, критичность оборудования и требования действующей документации. Предлагаемый нами метод разграничивает процедуры расчета RUL, преобразования прогноза в динамический индекс риска и RAG-поддержку; языковая модель используется для поиска и представления документальных оснований и не изменяет рассчитанные значения.

Цели и задачи

Цель исследования заключается в разработке метода прогнозирования остаточного ресурса средств КИПиА с динамической оценкой риска и RAG-поддержкой инженерных решений. Для ее достижения необходимо: формализовать прогноз RUL по данным состояния и обслуживания; сопоставить Random Forest, Gradient Boosting и LSTM по MAE, RMSE и направлению ошибки; учесть неопределенность прогноза; сформировать индекс риска по RUL, текущему отклонению и критичности; определить состав инженерной базы знаний и порядок RAG-поиска; проверить процедуру выбора модели на открытом наборе и задать порядок промышленной валидации.

Объект исследования – процессы предиктивного обслуживания средств КИПиА и анализаторных систем; предмет – методы прогнозирования остаточного ресурса, оценки риска и информационной поддержки инженера.

Методы

Для воспроизводимой демонстрации расчетной части используется NASA C-MAPSS FD001, содержащая 100 обучающих и 100 тестовых траекторий, один режим работы и один вид деградации [3]. Набор относится к авиационным двигателям и применяется только для проверки процедуры выбора прогнозной модели; перенос его численных параметров на КИПиА недопустим. Постановка run-to-failure и определение остаточного числа циклов приведены разработчиками C-MAPSS [4].

Для i -го средства КИПиА в момент t регистрируется вектор параметров

$$x_i(t) = [x_{i1}(t), x_{i2}(t), \dots, x_{i3}(t)].$$

Развитие состояния описывается окном длиной W , а остаточный ресурс – временем до принятого критерия предельного состояния:

$$X_i(t) = \{x_i(t-W+1), \dots, x_i(t)\},$$

$$L_i(t) = T_i^f - t.$$

Модель формирует прогноз с учетом режима эксплуатации $u_i(t)$ и истории обслуживания $h_i(t)$:

$$\hat{L}_i(t) = f_{\theta}(X_i(t), u_i(t), h_i(t)).$$

Набор признаков задается типом оборудования и может включать дрейф, шум, результаты самодиагностики, ошибки связи, температурные параметры, результаты проверок и контрольных проб. Кандидатами являются Random Forest [5], Gradient Boosting/XGBoost [6] и LSTM [7], применимость которой к RUL на C-MAPSS подтверждена ранее [8]. Выборка разделяется по единицам оборудования, исключая попадание наблюдений одного объекта одновременно в обучение и тестирование. Для вновь вводимого оборудования без собственной истории допускается использование данных однотипных средств КИПиА с последующей валидацией. При отсутствии данных прогноз RUL вводится после накопления собственной истории; до этого применяются регламентный и пороговый контроль. Точность оценивается по

$$MAE = \frac{1}{n} \sum_{i=1}^n |L_i - \hat{L}_i|,$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (L_i - \hat{L}_i)^2},$$

а направление ошибки по:

$$e_i = \hat{L}_i - L_i.$$

Положительное e_i означает завышение RUL и контролируется отдельно для критичных приборов. Точечная оценка дополняется интервалом

$$L_i^{LB}(t) \leq \hat{L}_i(t) \leq L_i^{UB}(t),$$

который может строиться методами конформного прогнозирования [9]. В оценке риска используется нижняя граница $L_i^{LB}(t)$.

Компонента близости к предупредительному горизонту L_i^{warn} задается как

$$r_i^{RUL}(t) = \min \left\{ 1, \max \left[0, 1 - \frac{L_i^{LB}(t)}{L_i^{warn}} \right] \right\}.$$

Текущее отклонение обозначается $a_i(t) \in [0; 1]$, критичность – $c_i \in [0; 1]$. Значение c_i определяется принятой на предприятии классификацией, FMEA или матрицей критичности. Связь RUL с планированием технических воздействий рассматривается в современных методах предиктивного обслуживания [10], а

динамическая оценка риска используется для корректировки планов по новым диагностическим данным [11]. Предлагаемый индекс имеет вид

$$R_i(t) = c_i [\alpha r_i^{RUL}(t) + (1 - \alpha) a_i(t)], 0 \leq \alpha \leq 1.$$

При порогах $0 < R_1 < R_2 \leq 1$ задаются три действия: $R_i < R_1$ – штатное наблюдение; $R_1 \leq R_i < R_2$ – дополнительная диагностика и инженерная рекомендация; $R_i \geq R_2$ – приоритетное рассмотрение обслуживания, ремонта или замены.

В табл. 1 отражена роль применяемых подходов в предлагаемом методе:

Таблица 1 – Роль применяемых подходов в предлагаемом методе

Подход	Исходная информация	Результат	Основное ограничение
Регламентный и пороговый контроль	сроки ТО, наработка, допустимые значения	сигнал о проверке или обслуживании	слабый учет индивидуальной деградации
ML-прогнозирование	временные ряды, признаки, история состояний	RUL и интервал и прогноз	зависимость от качества данных
Динамическая оценка риска	RUL, состояние, критичность	уровень риска	требуется настройка параметров
RAG-поддержка	расчетный запрос и база знаний	рекомендация со ссылками	зависимость от базы и поиска

Последовательность вычислений и выбора действия показана на рисунке 1.




Рисунок 1 – Метод прогнозирования RUL и динамической оценки риска средств КИПиА

Источник: составлено автором.

Инженерная база знаний задается как

$$K = \{d_1, d_2, \dots, d_M\},$$

и включает действующие руководства, регламенты, сервисные материалы, описания отказов, архивные заявки и проверенные отчеты. Фрагменты снабжаются метаданными о типе оборудования, изготовителе, модели, редакции и сроке действия документа. RAG связывает языковую модель с внешней памятью и поиском релевантных фрагментов [12]. После расчета формируется запрос

$$q_i(t) = \{I D_i, \hat{L}_i, L_i^{LB}, L_i^{UB}, R_i, a_i, z_i, m_i\},$$

по которому извлекается набор документов и формируется рекомендация:

$$D_i(t) = \underset{d_j \in K}{\text{Top}K} \sim (E(q_i(t)), E(d_j)),$$

$$A_i(t) = G(q_i(t), D_i(t)).$$

Применимость RAG к локальной технической информации показана для платформы эксплуатации виртуальной электростанции [13]; также развиваются решения связи LLM с детерминированными средствами промышленного мониторинга [14]. В предлагаемом методе индексируются только утвержденные редакции, ответ содержит ссылки на документы, при недостаточной релевантности рекомендация не формируется, а RUL и риск передаются в генеративный модуль как неизменяемые значения. Окончательное решение принимает инженер.

Структурная схема системы приведена на рисунке 2. Расчетный поток данных и поиск по базе знаний объединяются на этапе RAG-поддержки; подтвержденный результат обслуживания возвращается в систему ТОиР и после проверки может использоваться при последующем обучении.




Рисунок 2 – Структурная схема интеллектуальной системы предиктивного обслуживания средств КИПиА

Источник: составлено автором.

Результаты

Для апробации процедуры выбора использованы опубликованные результаты единого эксперимента на NASA C-MAPSS FD001. В исследовании 2026 г. Linear Regression, Gradient Boosting и Random Forest оценивались после одинаковой подготовки данных. Random Forest показал минимальный RMSE 17,09 цикла и максимальный $R^2=0,8181$, Gradient Boosting – минимальный MAE 12,05 цикла [15]. Исходные значения таблицы 2 взяты из указанной публикации, относительное снижение ошибок рассчитано автором.

Таблица 2 – Апробация процедуры выбора модели на NASA C-MAPSS FD001

Модель	RMSE, циклов	MAE, циклов	R^2	Снижение RMSE, %	Снижение MAE, %
Linear Regression	20,60	16,37	0,7357	–	–
Gradient Boosting	17,42	12,05	0,8111	15,44	26,39
Random Forest	17,09	12,10	0,8181	17,04	26,08

По сравнению с Linear Regression RMSE снизился на 15,44% для Gradient Boosting и на 17,04% для Random Forest; MAE – на 26,39 и 26,08%. Разница MAE **между ансамблевыми моделями** составляет 0,05 цикла. Поэтому для открытого примера базовой моделью принимается Random Forest по сочетанию RMSE и R^2 , однако универсальный алгоритм заранее не фиксируется. LSTM сохраняется среди кандидатов и должна сопоставляться **с ансамблевыми моделями** на общей выборке конкретного класса КИПиА. Дополнительно проверяются положительные ошибки e_i , поскольку систематическое завышение RUL для критичного прибора недопустимо.

Динамический индекс переводит прогноз в уровень срочности, т.к. малая нижняя граница RUL и высокая критичность повышают $R_i(t)$ даже при одинаковом текущем отклонении. Параметры α , L_i^{warn} , R_1 и R_2 калибруются для конкретного класса оборудования и принятого уровня риска.

Промышленная проверка выполняется на истории, связанной с подтвержденными отказами, ремонтами, поверками и заменами. Данные разделяются по единицам оборудования; для прогнозной модели рассчитываются MAE, RMSE, распределение e_i и покрытие интервалов. RAG оценивается отдельно по релевантности найденных источников, корректности ссылок на редакции документов и экспертной приемке рекомендаций.

Таблица 3 – Показатели промышленной валидации предлагаемого метода

Этап	Проверяемый показатель	Назначение	Принцип приемки
Прогноз RUL	MAE, RMSE	средняя точность	сравнение кандидатов на общей тестовой выборке
Направленная ошибка	доля и величина $e_i > 0$	контроль завышения RUL	отдельный предел для критичных КИПиА
Интервальный прогноз	фактическое покрытие	оценка неопределенности	соответствие заданному уровню покрытия
Динамический риск	стабильность категорий, запоздалые решения	связь прогноза с действием	исторические события и экспертная проверка
RAG-поддержка	релевантность и корректность ссылок	качество рекомендации	утвержденные документы и прослеживаемая выдача

Полная промышленная апробация в работе не имитируется, т.е. C-MAPSS подтверждает воспроизводимость процедуры выбора RUL-модели. Для внедрения на предприятии последовательно определяются критерий предельного состояния, формируется история наблюдений, выбирается модель, калибруются интервалы и параметры риска, затем проверяется база знаний и поисковая выдача RAG. Окончательное решение сохраняется за ответственным специалистом.

Заключение

Таким образом, в исследовании разработан метод прогнозирования остаточного ресурса средств КИПиА, связывающий RUL, динамическую оценку риска и RAG-поддержку. Формализован прогноз по данным состояния и обслуживания; выбор модели выполняется по MAE, RMSE и направлению ошибки. Точечная оценка дополняется интервалом, нижняя граница которого участвует в расчете риска совместно с текущим отклонением и критичностью оборудования.

На базе NASA C-MAPSS FD001 Random Forest показал лучший RMSE и R^2 , Gradient Boosting – минимальный MAE. Снижение RMSE относительно Linear Regression составило 17,04% и 15,44% соответственно для Random Forest и Gradient Boosting. Результат подтверждает необходимость многокритериального выбора после переноса метода на конкретный класс средств КИПиА.

Для RAG определены состав базы знаний и ограничения генеративного модуля, т.к. рассчитанные RUL и риск не изменяются, а рекомендация сопровождается ссылками на актуальные документы. Дальнейшая проверка требует эксплуатации до отказа истории по КИПиА, калибровки параметров риска и экспертной оценки RAG-рекомендаций на производственных запросах.

Научная новизна исследования состоит в предлагаемом методе для средств КИПиА, в котором консервативная граница RUL совместно с текущим отклонением и критичностью преобразуется в динамический риск, а расчетный результат включается в формализованный запрос к инженерной базе знаний.

Практическая значимость связана с последовательным переходом от оценки деградации к прослеживаемой рекомендации специалисту.

Список литературы

1. Ершов А. Н. Актуальные проблемы развития предиктивной аналитики в промышленности // Вестник Магнитогорского государственного технического университета им. Г. И. Носова. 2025. Т. 23. № 3. С. 187–194. DOI: 10.18503/1995-2732-2025-23-3-187-194.
2. Taşcı B., Omar A., Ayvaz S. Remaining useful lifetime prediction for predictive maintenance in manufacturing // Computers & Industrial Engineering. 2023. Vol. 184. Art. 109566. DOI: 10.1016/j.cie.2023.109566.
3. CMAPSS Jet Engine Simulated Data // NASA Open Data Portal. URL: <https://data.nasa.gov/dataset/cmapss-jet-engine-simulated-data> (дата обращения: 04.08.2026).
4. Saxena A., Goebel K., Simon D., Eklund N. Damage propagation modeling for aircraft engine run-to-failure simulation // Proceedings of the 1st International Conference on Prognostics and Health Management. Denver, 2008. P. 1–9. DOI: 10.1109/PHM.2008.4711414.
5. Breiman L. Random Forests // Machine Learning. 2001. Vol. 45. P. 5–32. DOI: 10.1023/A:1010933404324.
6. Chen T., Guestrin C. XGBoost: A Scalable Tree Boosting System // Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. 2016. P. 785–794. DOI: 10.1145/2939672.2939785.
7. Hochreiter S., Schmidhuber J. Long Short-Term Memory // Neural Computation. 1997. Vol. 9. No. 8. P. 1735–1780. DOI: 10.1162/neco.1997.9.8.1735.
8. Zhang J., Wang P., Yan R., Gao R. X. Long short-term memory for machine remaining life prediction // Journal of Manufacturing Systems. 2018. Vol. 48. P. 78–86. DOI: 10.1016/j.jmsy.2018.05.011.
9. Javanmardi A., Hüllermeier E. Conformal Prediction Intervals for Remaining Useful Lifetime Estimation // International Journal of Prognostics and Health Management. 2023. Vol. 14. No. 2. DOI: 10.36001/ijphm.2023.v14i2.3417.

10. Wang L., Zhu Z., Zhao X. Dynamic predictive maintenance strategy for system remaining useful life prediction via deep learning ensemble method // Reliability Engineering & System Safety. 2024. Vol. 245. Art. 110012. DOI: 10.1016/j.ress.2024.110012.
11. Dynamic Risk Assessment for CBM-based adaptation of maintenance planning / P. Martínez-Galán Fernández, A. J. Guillén López, A. Crespo Márquez и др. // Reliability Engineering & System Safety. 2022. Vol. 223. Art. 108359. DOI: 10.1016/j.ress.2022.108359.
12. Retrieval-Augmented Generation for Knowledge-Intensive NLP Tasks / P. Lewis, E. Perez, A. Piktus и др. // Advances in Neural Information Processing Systems. 2020. Vol. 33. P. 9459–9474.
13. Implementation of a Device Failure Query Model for the Virtual Power Plant Smart Operation and Maintenance Platform Based on Retrieval-Augmented Generation Technology / Z. Li, Y. Zhao, X. Zhu и др. // Electronics. 2025. Vol. 14. No. 22. Art. 4502. DOI: 10.3390/electronics14224502.
14. Di Maggio L. G. Predictive Maintenance MCP: An Open-Source Framework for Bridging Large Language Models and Industrial Condition Monitoring via the Model Context Protocol // Applied Sciences. 2026. Vol. 16. No. 6. Art. 2812. DOI: 10.3390/app16062812.
15. Tezcan M. K., Kuscu H. Predictive Maintenance via Remaining Useful Life Estimation in Jet Engine Systems: A Comparative Analysis of Machine Learning Approaches Using the NASA CMAPSS Dataset // Engineering Proceedings. 2026. Vol. 150. No. 1. Art. 75. DOI: 10.3390/engproc2026150075.