

ПРОГНОЗИРОВАНИЕ ТЕХНИЧЕСКОГО ОБСЛУЖИВАНИЯ АВИАЦИОННЫХ ДВИГАТЕЛЕЙ НА ОСНОВЕ ГЛУБОКОГО ОБУЧЕНИЯ

Е.Л. Кулида

Институт проблем управления им. В.А. Трапезникова РАН
Россия, 117997, Москва, Профсоюзная ул., 65
E-mail: elena-kulida@yandex.ru

В.Г. Лебедев

Институт проблем управления им. В.А. Трапезникова РАН
Россия, 117997, Москва, Профсоюзная ул., 65
E-mail: lebedev-valentin@yandex.ru

Ключевые слова: техническое обслуживание, прогнозирование оставшегося срока службы авиационных двигателей, нейронные сети, глубокое обучение с подкреплением

Аннотация: В докладе представлена технология прогнозирования оставшегося срока службы авиационных двигателей для их прогнозируемого технического обслуживания. Рассмотрен метод обнаружения редких отказов с использованием подхода глубокого гибридного обучения на основе несбалансированного набора данных. Представлен метод глубокого обучения с подкреплением для оптимального планирования замены двигателей, для того чтобы избежать отказов и свести к минимуму потерянный срок службы двигателей. Оптимальное планирование замены двигателей использует распределение вероятностей оставшегося полезного срока службы авиационных двигателей, рассчитываемое на основе сверточных нейронных сетей и метода исключения Монте-Карло.

1. Введение

Расходы на техническое обслуживание летательных аппаратов (ЛА) составляют около 10-20 % от общих эксплуатационных расходов. Поэтому получение упреждающей оценки технического состояния и прогнозирование оставшегося срока службы (RUL – Remaining Useful Life) систем и/или оборудования, подвергающихся старению или деградации, признано очень важным для повышения эффективности эксплуатации ЛА и оптимизации их технического обслуживания [1]. Диагностика и прогнозирование технического состояния двигателя имеют решающее значение для обеспечения безопасной эксплуатации ЛА и разработки планов технического обслуживания. Отказы двигателей могут привести к большим экономическим потерям, экологическому ущербу и даже в крайних случаях к авариям.

Прогнозируемое техническое обслуживание осуществляется с использованием фактических данных о состоянии работоспособности двигателя в процессе эксплуатации с целью предупреждения неисправностей до их появления, а не в соответствии с регламентом технического обслуживания. В зависимости от используемых подходов предлагаемые методы прогнозирования разделяются на три группы: основанные на моделях, управляемые данными и гибридные.

Использование моделей требует понимания фундаментальных физических принципов работы и механизмов отказов двигателя. Процесс создания математических моделей двигателей очень сложен, поэтому основные исследования сосредоточены на методах, основанных на данных, которые имеют преимущество при отсутствии точной математической модели или подробных экспертных знаний о двигателе. Подход, основанный на данных, предполагает диагностику двигателя на основе собранных исторических эксплуатационных данных для прогнозирования будущего состояния. Эксплуатационные данные, генерируемые датчиками технического состояния ЛА, крайне несбалансированные, поскольку отказы двигателей происходят во время полетов чрезвычайно редко и данные смещены в сторону нормальной работы. В этом случае необходимы специальные методы анализа для противодействия дисбалансу данных. Методы прогнозирования на основе данных используют алгоритмы искусственного интеллекта, в том числе, машинного обучения и глубокого обучения. В последнее время было показано, что модели глубокого обучения обеспечивают очень высокую производительность при обучении на больших наборах данных благодаря их способности сочетать извлечение признаков с обучением [2].

Для решения проблемы оценки оставшегося срока полезного использования двигателя предложен также ряд гибридных подходов, основанных на физических моделях и анализе данных, которые показали многообещающую эффективность. В зависимости от того, какой тип информации обрабатывается и как фрагменты информации объединяются, предложены различные типы гибридных архитектур [3]. В настоящее время универсальной прогностической модели не существует и ее выбор может зависеть от конкретных характеристик отдельных двигателей [4].

2. Методы обнаружения редких отказов на основе несбалансированных наборов данных

При полетах современных самолетов генерируются большие объемы данных мониторинга состояния, в частности для двигателя Боинга 787 непрерывно контролируется около 1000 параметров [5], которые являются основой для оценки оставшегося полезного срока службы и прогнозирования технического обслуживания.

Из-за отсутствия размеченных наборов данных для прогнозирования оставшегося полезного срока службы в основном используются неконтролируемые и полуконтролируемые методы. Одним из популярных подходов является обучение без учителя модели на основе автоэнкодера для изучения нормального функционирования системы, чтобы в дальнейшем модель смогла обнаруживать аномальные состояния.

Многие модели прогнозирования оставшегося полезного срока службы основаны на сверточных нейронных сетях [6], глубоких сверточных нейронных сетях [7], многомасштабных глубоких сверточных нейронных сетях [8], сверточных сетях с объединением [9, 10], а также гибридном подходе на основе моделей и глубокого обучения [3].

В работе [11] представлен метод обнаружения редких отказов для прогнозируемого обслуживания самолетов с использованием подхода глубокого гибридного обучения на основе несбалансированного набора данных. Предлагаемая модель использует два этапа: автоэнкодер для обнаружения редких сбоев и сверточную нейронную сеть с двунаправленными управляемыми рекуррентными блоками (Bidirectional Gated Recurrent Unit, BGRU) – для прогнозирования следующего возникновения сбоя.

Процесс кодирования-декодирования на первом этапе представляется в виде:

$$p_i = f(w_p, x_i + b_t),$$

$$y_i = g(w_y p_i + b_t),$$

где $f(\cdot)$ и $g(\cdot)$ – сигмоидные функции, w_i – веса, b_i – смещения.

Обучение осуществляется с использованием алгоритма обратного распространения ошибки относительно функции потерь:

$$L(X, Y) = \frac{1}{n} \sum_i^n \|x_i - y_i\|^2,$$

где x_i – наблюдаемое значение, y_i – прогнозируемое значение, n – количество прогнозируемых значений.

Двунаправленный управляемый рекуррентный блок состоит из ячеек с памятью – GRU Block (рис. 1), которые предназначены для решения проблемы исчезновения градиента. Входные данные попадают в два слоя: прямой и обратный по времени, которые подключены к одному выходному слою. Двунаправленный подход обеспечивает возможность использования как прошлого, так и будущего контекста.

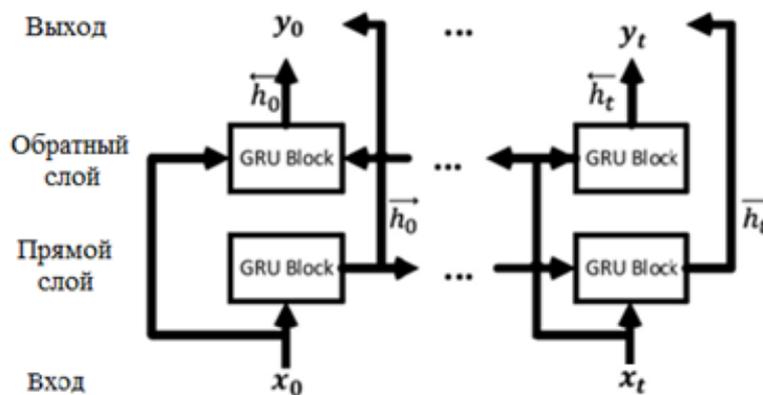


Рис. 1. Архитектура двунаправленного управляемого рекуррентного блока.

Предлагаемый метод оценивается с использованием данных реальной системы технического обслуживания самолетов. Результаты оценки свидетельствуют, что метод эффективен для прогнозирования отказов компонентов в течение заранее определенного значимого периода времени.

3. Глубокое обучение с подкреплением для планирования технического обслуживания авиационных двигателей

В прогнозировании большое значение имеет учет неопределенности, присущей моделям и данным. В результате, чтобы прогноз оставшегося полезного срока службы имел смысл, он должен, по крайней мере, сопровождаться доверительными интервалами и, что еще лучше, описанием через распределения вероятностей, если это вообще возможно, или нечеткими представлениями [12].

В работе [13] предлагается подход к интеграции распределения вероятностей оставшегося полезного срока службы авиационных двигателей в оптимальное планирование замены двигателей. Вероятностные прогнозы рассчитываются на основе сверточных нейронных сетей и метода исключения Монте-Карло [14]. С использованием полученных вероятностных прогнозов разрабатывается метод на основе глубокого обучения с подкреплением для планирования технического обслуживания авиационных двигателей. Целью является оптимальное планирование замены двигателей, чтобы избежать отказов и свести к минимуму потеранный срок службы двигателей [13].

График технического обслуживания обновляется каждые D летных циклов. На шаге принятия решения t по измерениям датчиков x_t оценивается $p_{k,t}$ – предполагаемая вероятность того, что оставшийся полезный срок службы двигателя меньше или равен k циклам при x_t :

$$p_{k,t} = P(R_t \leq k | x_t) \text{ для } k \in \{1, \dots, D\}.$$

Двигатель выходит из строя на $-m$ цикле, если $(k - 1) < \rho_t \leq k$, где ρ_t – истинный оставшийся полезный срок службы двигателя, R_t – прогнозируемый оставшийся полезный срок службы двигателя в начале шага t .

Состояние s_t определяется предполагаемым распределением $p_{k,t}$ для следующих D летных циклов:

$$s_t = [p_{1,t}, \dots, p_{D,t}].$$

На основе состояния S_t агент выбирает действие:

$$a_t = \begin{cases} k, & 0 < k \leq D \text{ Заменить двигатель в цикле } k \\ M, & M > D \text{ Не заменять двигатель} \end{cases}.$$

Если агент решает не заменять двигатель, то на следующем шаге $t+1$ измерения датчиков x_t и распределения $p_{k,t}$ обновляются. Это позволяет принимать решения на основе последних прогнозов.

Награда r_t на шаге t зависит от a_t и ρ_t :

$$r_t = \begin{cases} -c_{sch}(k), & \text{если } (k - 1 < a_t \leq k) \& (\rho_t > k) \\ -c_{uns}, & \text{если } (k - 1 < a_t \leq k) \& (\rho_t \leq k) \\ -c_{uns}, & \text{если } (a_t > D) \& (\rho_t \leq D) \\ 0, & \text{если } (a_t > D) \& (\rho_t > D) \end{cases},$$

где $c_{sch}(k) = c_0 - c_1 k$ – стоимость плановой замены двигателя в цикле k , $c_0 > 0$ – фиксированная стоимость замены, $c_1 > 0$ – штраф за досрочную замену, $c_{uns} > c_0$ – стоимость внеплановой замены.

Агент выбирает действие a_t в состоянии s_t на основе стратегии $\pi(a_t | s_t)$, которая определяет вероятность выбора действия a_t в состоянии s_t . Оптимальная стратегия π^* максимизирует ожидаемое вознаграждение:

$$J(\pi) = \sum_t \mathbb{E}_{(s_t, a_t) \sim \rho_\pi} [\gamma^t r_t(s_t, a_t)],$$

где γ – коэффициент дисконтирования, $\rho_\pi(s_t, a_t)$ – распределение траекторий состояние-действие при следовании стратегии π .

Для обучения агента используется мягкий алгоритм «исполнитель-критик» [15]. По сравнению с алгоритмом «исполнитель-критик» этот алгоритм использует стохастическую политику и максимизирует мягкую цель для изучения новых политик. Это позволяет определить оптимальный момент замены двигателя с учетом различных тенденций распределения оставшегося полезного срока службы. Такой подход позволит снизить затраты на техническое обслуживание и уменьшить количество внеплановых мероприятий по сравнению с другими стратегиями технического обслуживания.

4. Заключение

Подход к техническому обслуживанию по состоянию на основе систем прогнозирования и управления работоспособностью – это целостный подход к эффективному управлению техническим состоянием авиационных двигателей от обнаружения, диагностики зарождающейся неисправности и прогнозирования оставшегося полезного срока службы до принятия своевременных и оптимальных действий по техническому обслуживанию, позволяющих обеспечить безопасность и минимизировать затраты.

Предполагается, что в будущем применение глубокого обучения позволит решить сложные проблемы прогнозирования и управления работоспособностью, которые невозможно было решить с помощью традиционных подходов, либо повысить производительность традиционных подходов, автоматизировать разработку прикладных моделей, повысить их надёжность и снизить затраты на их использование.

При планировании технического обслуживания использование глубокого обучения с подкреплением позволит адаптироваться к текущим проблемам в процессе взаимодействия со средой.

Исследование выполнено частично за счёт гранта Российского научного фонда № 23-19-00464, <https://rscf.ru/project/23-19-00464>.

Список литературы

1. Kordestani M., Orchard M.E., Khorasani K., Saif M. An Overview of the State of the Art in Aircraft Prognostic and Health Management Strategies // *IEEE Transaction on Instrumentation and Measurement*. 2023. Vol. IM-72. 3505215. DOI: 10.1109/TIM.2023.3236342.
2. Stanton I., Munir K., Ikram A., El-Bakry M. Predictive Maintenance Analytics and Implementation for Aircraft: Challenges and Opportunities // *Systems Engineering*. 2023. Vol. 26, No. 2. P. 216-237. DOI: 10.1002/sys.21651.
3. Chao M.A., Kulkarni C., Goebel K., Fink O. Fusing Physics-based and Deep Learning Models for Prognostics // *Reliability Engineering and System Safety*. 2022. Vol. 217. No. 3. P. 107961. DOI: 10.1016/j.res.2021.107961.
4. Fu S., Avdelidis N.P. Prognostic and Health Management of Critical Aircraft Systems and Components: An Overview // *Sensors*. 2023. Vol. 23, No. 19. P. 8124. DOI: 10.3390/s23198124.
5. Badea V.E., Zamfiroiu A., Boncea R. Big Data in the Aerospace Industry // *Informatica Economica*. 2018. Vol. 22, No. 1. P. 17-24. DOI: 10.12948/issn14531305/22.1.2018.02.
6. Pater I., Reijns A., Mitici M. Alarm-based Predictive Maintenance Scheduling for Aircraft Engines with Imperfect Remaining Useful Life Prognostics // *Reliability Engineering System Safety*. 2022. Vol. 221. P. 108341. DOI: 10.1016/j.res.2022.108341.
7. Li X., Ding Q., Sun J.Q. Remaining Useful Life Estimation in Prognostics Using Deep Convolution Neural Networks // *Reliability Engineering System Safety*. 2018. Vol. 172, No. 1-2. DOI: 10.1016/j.res.2017.11.021.
8. Li H., Zhao W., Zhang Y., Zio E. Remaining Useful Life Prediction Using Multiscale Deep Convolutional Neural Network // *Applied Soft Computing*. 2020. Vol. 89. P. 106113. DOI: 10.1016/j.asoc.2020.106113.
9. Babu G.S., Zhao P., Li X-L. Deep Convolutional Neural Network Based Regression Approach for Estimation of Remaining Useful Life // *International Conference on Database Systems for Advanced Applications (DASFAA)*. Dallas.TX.USA. 2016. Vol. 9642. P. 214-228. DOI: 10.1007/978-3-319-32025-0_14.
10. Song Y., Blik L., Xia T., Zhang Y. A Temporal Pyramid Pooling-Based Convolutional Neural Network for Remaining Useful Life Prediction // *Proceedings of the 31st European Safety and Reliability Conference*. 2021. P. 810-817. DOI: 10.3850/978-981-18-2016-8_478-cd.
11. Dangut M.D., Jennions I.K., King S., Skaf Z. A Rare Failure Detection Model for Aircraft Predictive Maintenance Using a Deep Hybrid Learning Approach // *Neural Computing and Applications*. 2023. Vol. 35, No. 4. P. 2991-3009. DOI: 10.1007/s00521-022-07167-8.
12. Fink O., Wang Q., Svensén M., Dersin P., Lee W.J., Ducoffe M. Potential, Challenges and Future Directions for Deep Learning in Prognostics and Health Management Applications // *Engineering Applications Artificial Intelligence*. 2020. Vol. 92, No. 033. P. 103678. DOI: 10.1016/j.engappai.2020.103678.
13. Lee J., Mitichi, M. Deep Reinforcement Learning for Predictive Aircraft Maintenance Using Probabilistic Forecast of Remaining Useful Life // *Reliability and System Safety*. 2023. Vol. 230, No. 1. P. 108908. DOI: 10.1016/j.res.2022.108908.
14. Srivastava N., Hinton G., Sutskever A., Krizhevsky I., Salakhutdinov R. Dropout: A Simple Way to Prevent Neural Networks from Overfitting // *Journal of Machine Learning Research*. 2014. Vol. 15. DOI: 10.5555/2627435.2670313.
15. Haarnoja T., Zhou A., Abbeel P., Levine S. Soft Actor-critic: Off-policy Maximum Entropy Deep Reinforcement Learning with a Stochastic Actor // *35th International Conference on Machine Learning (ICML)*. Stockholm, Sweden. Aug 2018. Vol. 5. P. 2976–2989. arXiv:1801.01290v2 [cs.LG] 8 Aug 2018.