

ИСПОЛЬЗОВАНИЕ МЕТОДОВ ГЛУБОКОГО ОБУЧЕНИЯ ДЛЯ ПРОГНОЗНОГО ОБСЛУЖИВАНИЯ АВИАЦИОННЫХ ДВИГАТЕЛЕЙ¹

Кулида Е.Л., Лебедев В.Г.

Институт проблем управления им. В.А. Трапезникова РАН, Москва, Россия
elena-kulida@yandex.ru, lebedev-valentin@yandex.ru

Аннотация. Рассмотрены подходы к выявлению аномалий в данных с помощью автоэнкодеров и прогнозированию оставшегося срока полезного использования авиационных двигателей на основе моделей глубокого обучения, управляемых данными. Рассмотрена задача планирования технического обслуживания авиационных двигателей на основе обучения с подкреплением.

Ключевые слова: прогнозирование технического состояния, оставшийся срок полезного использования, данные мониторинга, автоэнкодер, глубокое обучение, обучение с подкреплением.

Введение

Существуют разные подходы к техническому обслуживанию авиационных двигателей. Внеплановое техническое обслуживание – при возникновении неисправности – может привести к нежелательным простоям и увеличивает эксплуатационные расходы. По данным Airbus [1] к 2025 году внеплановых ремонтов самолетов быть не должно. Для предотвращения незапланированных событий используется плановое профилактическое техническое обслуживание. Прогнозное обслуживание должно обеспечить экономию средств, поскольку будет проводиться не по времени, а в зависимости от состояния двигателя, но для этого необходимо прогнозирование технического состояния и определения оставшегося срока полезного использования.

Техническое обслуживание авиационных двигателей по состоянию имеет большое значение для повышения эффективности и безопасности гражданской авиации. Полезным источником информации для анализа технического состояния и прогнозирования оставшегося срока полезного использования авиационных двигателей могут служить большие объемы данных, которые записываются в реальном времени в процессе полетов. Например, для двигателя Боинга 787 непрерывно контролируется около 1000 параметров, что составляет 20 терабайт данных за час полета [2]. Данные функционирования авиационных двигателей, записанные в процессе полетов, представляют собой многомерные временные ряды контролируемых параметров, которые не размечены и сильно смещены в сторону нормального функционирования.

1. Подходы к прогнозному техническому обслуживанию

Подходы к прогнозному обслуживанию могут быть основаны на моделировании физических процессов (концепция цифрового двойника), или на анализе данных мониторинга (таблица 1).

Использование моделей требует всестороннего понимания фундаментальных физических механизмов отказа и принципов работы, и для сложных систем получить такие модели сложно. По мере увеличения доступности данных, усовершенствования аппаратного и программного обеспечения, а также прорывов в разработке алгоритмов значительно улучшилась эффективность моделей глубокого обучения. Они позволяют прогнозировать будущие состояния без физических моделей, но точность прогнозов зависит от объема и качества используемых данных. Датчики должны обладать способностью точно определять количественные изменения параметров, связанных с механизмами отказов

Подходы, основанные на данных, обладают преимуществом перед методами, основанными на физике, поскольку в практических промышленных приложениях получение достоверных данных является более осуществимой задачей, чем разработка адекватных физических моделей механизмов отказа и принципов работы сложных систем.

¹ Исследование выполнено частично за счёт гранта Российского научного фонда № 23-19-00464, <https://rscf.ru/project/23-19-00464>.

Таблица 1. Сравнение подходов к прогнозному техническому обслуживанию

Подход	Преимущества	Недостатки
Модели, основанные на физическом моделировании	Повышенная точность. Можно рассчитать динамику состояний. Можно установить пороги отказов. Возможно моделировать несколько неисправностей.	Требуется всестороннее понимание фундаментальных физических механизмов отказа и принципов работы. Для сложных систем получить такие модели очень сложно
Модели, управляемые данными	Простая реализация. Прогнозирование будущих состояний не требует физических моделей. Низкая стоимость.	Точность прогнозов зависит от объема и качества используемых данных. Датчики должны обладать способностью точно определять количественные изменения параметров, связанных с механизмами отказов. Установление порогов отказов – сложная задача. Сложность учета условий эксплуатации.

Традиционные методы машинного обучения предполагают ручную инженерию признаков для каждой конкретной задачи, что существенно затрудняет их использование. Разработки в области глубокого обучения позволяют автоматически извлекать признаки из исходного набора данных во время обучения, причем при обработке больших объемов данных нейронная сеть выделяет признаки лучше человека (рис. 1) [3].

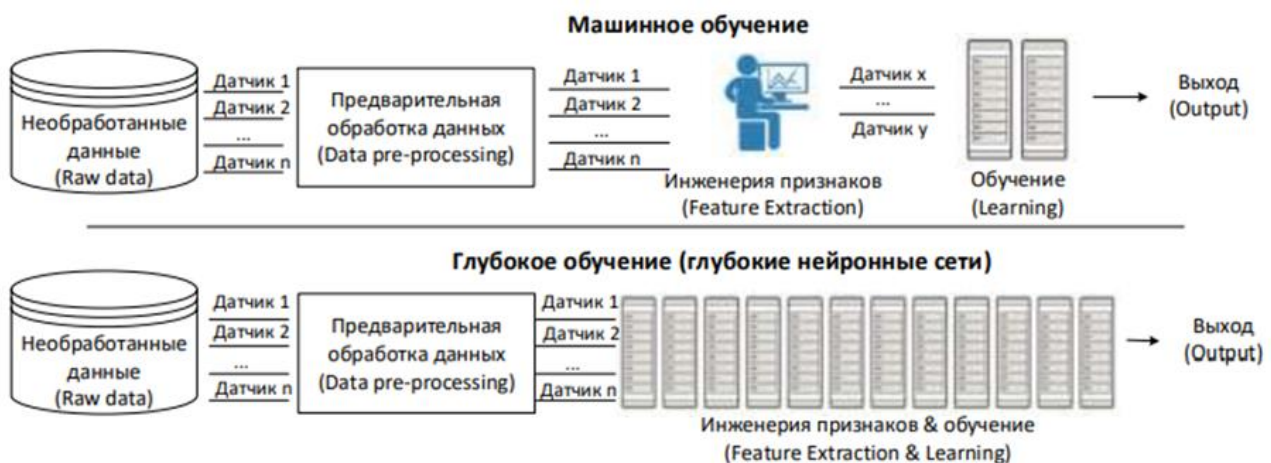


Рис. 1. Сравнение традиционного машинного обучения и глубокого обучения

Методы глубокого обучения становятся все более популярным способом поиска закономерностей в больших объемах данных во многих областях, в том числе в авиационной области [4]. Большое количество исследований посвящено применению методов глубокого обучения для решения задач диагностики технического состояния и организации технического обслуживания по состоянию. Наличие незамеченных данных в данных мониторинга авиационных двигателей предполагает использование неконтролируемых или полуконтролируемых методов. Наличие дисбаланса в данных требует разработки специальных алгоритмов для их анализа и прогнозирования редких отказов. Серьезной проблемой является оценка точности прогнозирования.

2. Выявление аномалий с помощью автоэнкодеров

Важной составной частью прогнозного технического обслуживания является обнаружение аномалий в данных. Автоэнкодер состоит из двух частей: кодера и декодера. Входной вектор $x \in R^n$ с помощью функции кодирования отображается в скрытое представление $h \in R^m$:

$$h = f_{\theta}(x) = S1(W * x + b) \quad (1)$$

$$S1(x) = \max(0, x), \quad (2)$$

где W – весовая матрица размером $m \times n$, $b \in R^n$ – вектор смещения, $S1(\cdot)$ – функция активации ReLU.

Затем скрытое представление при помощи функции декодирования отображается в выходной вектор:

$$z = g_{\theta'}(h) = S2(W' * h + b') \quad (3)$$

$$S2(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}, \quad (4)$$

где W' – весовая матрица размером $n \times m$, b' – вектор смещения, $S2(\cdot)$ – функция активации tanh.

Целевая функция модели – сумма всех квадратичных ошибок между входным и выходным векторами:

$$J(\theta, \theta') = \sum_{x \in D} L(x, z), \quad (5)$$

где L – квадратичная ошибка, D – обучающий набор данных.

Целевая функция минимизируется с помощью алгоритма обратного распространения ошибки для нахождения оптимальных параметров $\{\theta, \theta'\} = \{W, b, W', b'\}$.

Для построения глубокого автоэнкодера обучающий набор данных разделяется на несколько мини-пакетов, обновление параметров происходит на основе минимизации функции потерь для мини-пакета:

$$L(x, z) = \frac{1}{K} \sum_{k=1}^K \|x_k - z_k\|^2, \quad (6)$$

где K – размер мини-пакета.

Однако традиционные глубокие автоэнкодеры плохо справляются с несбалансированными данными, в то время как данные мониторинга двигателей крайне несбалансированные, поскольку данных о нормальной работе существенно больше, чем об аномальной, а образцов некоторых видов аномальной работы вообще может не быть.

В работе [5] представлен оптимизированный глубокий автоэнкодер для обнаружения аномалий работы газовых турбин на основе неразмеченных данных эксплуатации (рис. 2).

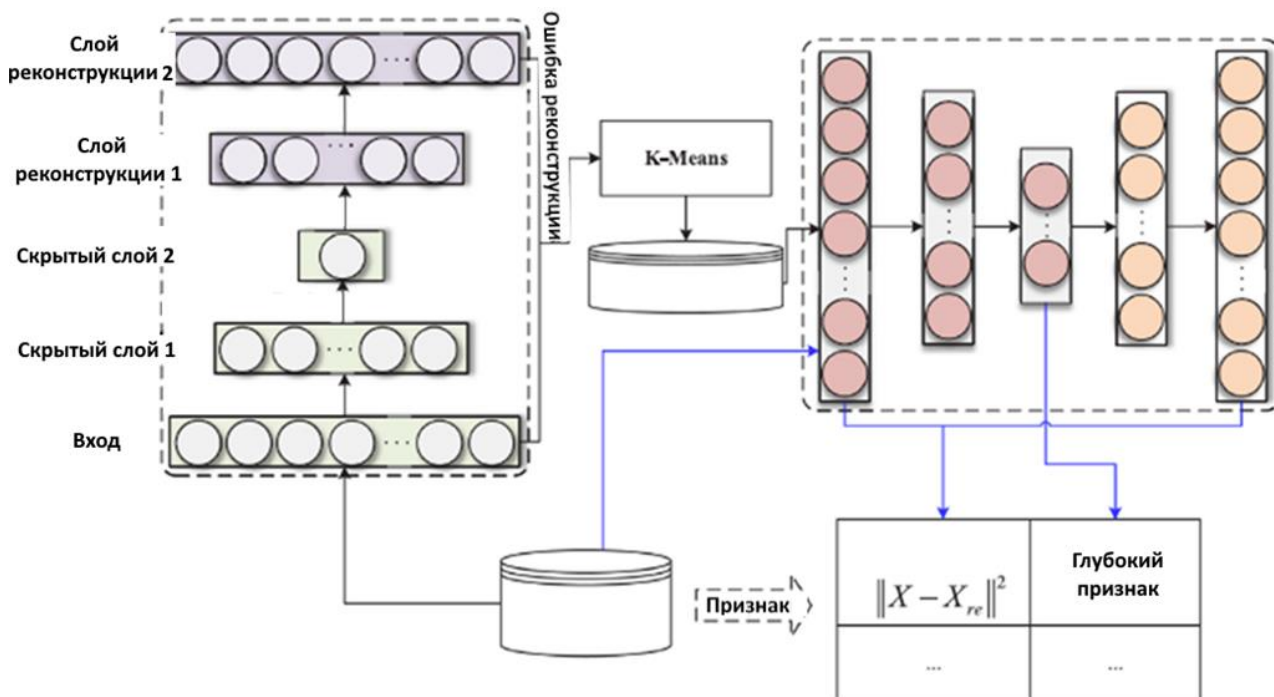


Рис. 2. Оптимизированный глубокий автоэнкодер для обнаружения аномалий

В основе лежит механизм, который позволяет автоматически удалять аномальные выборки из неразмеченного обучающего набора, и обучать автоэнкодер с использованием только нормальных выборок. Это позволяет сделать ошибки при декодировании аномальных выборок более отличимыми от ошибок при декодировании нормальных выборок. Оптимизированный автоэнкодер состоит из двух традиционных глубоких автоэнкодеров и алгоритма кластеризации. Первый автоэнкодер обучается на исходном наборе, и обученная модель используется для расчета ошибок для входных векторов. Индикатором аномалии служит ошибка реконструкции между входным вектором и его

низкоуровневой реконструкцией. Полученные ошибки при помощи алгоритма кластеризации разбиваются на два класса, при этом выборки с большими ошибками реконструкции рассматриваются как аномальные выборки. Формируется новый обучающий набор из кластера векторов с небольшими ошибками. По сравнению с исходным набором новый обучающий набор содержит меньше или даже совсем не содержит векторов для аномальных состояний. Второй автоэнкодер, обученный минимизировать ошибки декодирования на новом обучающем наборе, сможет лучше обнаруживать аномалии.

После этого, изученные при помощи оптимизированного автоэнкодера ошибки реконструкции и скрытые функции из исходных выборок вместе передаются в изолирующий лес для неконтролируемого обнаружения аномалий. Авторы предлагают использовать образцы нескольких двигателей, поскольку это хорошо устраняет негативное влияние отдельных различий больших механизмов на обнаружение аномалий и эффективно решает проблему недостаточного обучения, вызванную недостаточным количеством образцов для одного двигателя.

3. Архитектура глубоких нейронных сетей для прогнозирования оставшегося срока полезного использования авиационных двигателей

Добавление в модель одномерных сверточных нейронных слоев позволяют понять взаимосвязь между переменными в наборе данных и повысить точность при прогнозировании оставшегося срока полезного использования авиационных двигателей на основе данных временных рядов (рис. 3).

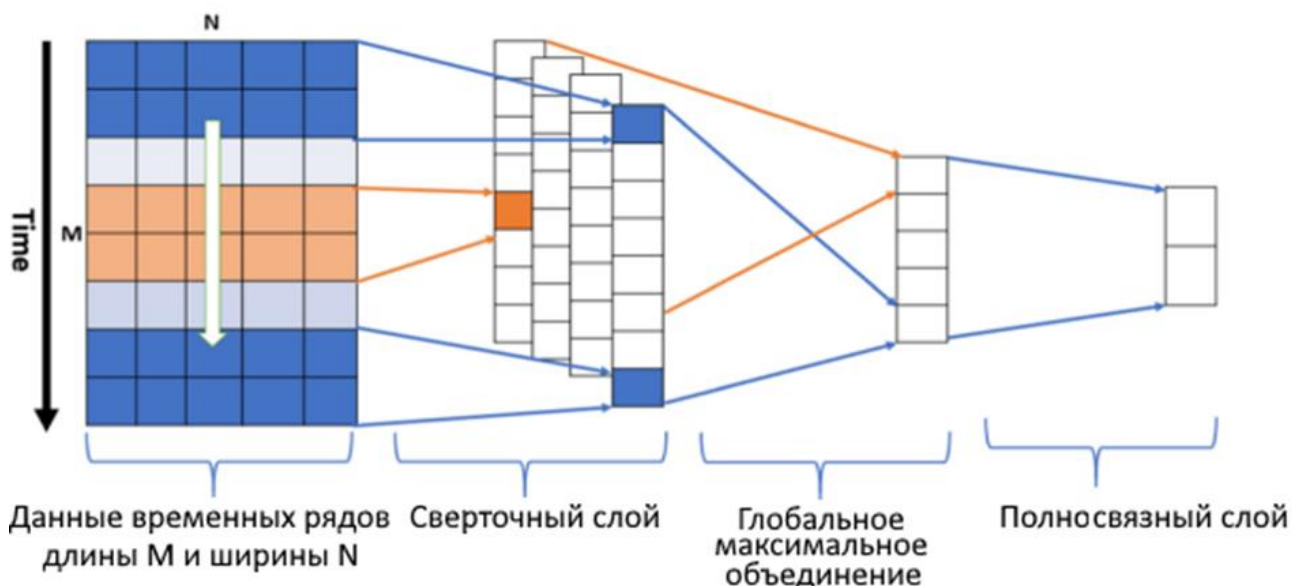


Рис. 3. Применение сверточных нейронных сетей для временных рядов

Рекуррентные сети используют внутреннюю память для эффективной обработки входных последовательностей. Важной разновидностью рекуррентных нейронных сетей являются сети, в которых используются ячейки долгой краткосрочной памяти LSTM (Long Short Term Memory) и рекуррентные блоки с вентилями GRU (Gated Recurrent Unit) – это специально разработанные ячейки с системой фильтров, которые благодаря своей структуре решают проблему исчезновения градиента и способны к обучению долгосрочным зависимостям. Двухнаправленные BLSTM и BGRU: входные данные подаются в двух направлениях: в прямой и обратный слои, сети могут использовать информацию как из прошлого, так и из будущего контекста в своих прогнозах (рис. 4).

Рекуррентные сети с ячейками BLSTM и BGRU являются мощным инструментом для прогнозирования оставшегося срока полезного использования авиационных двигателей.

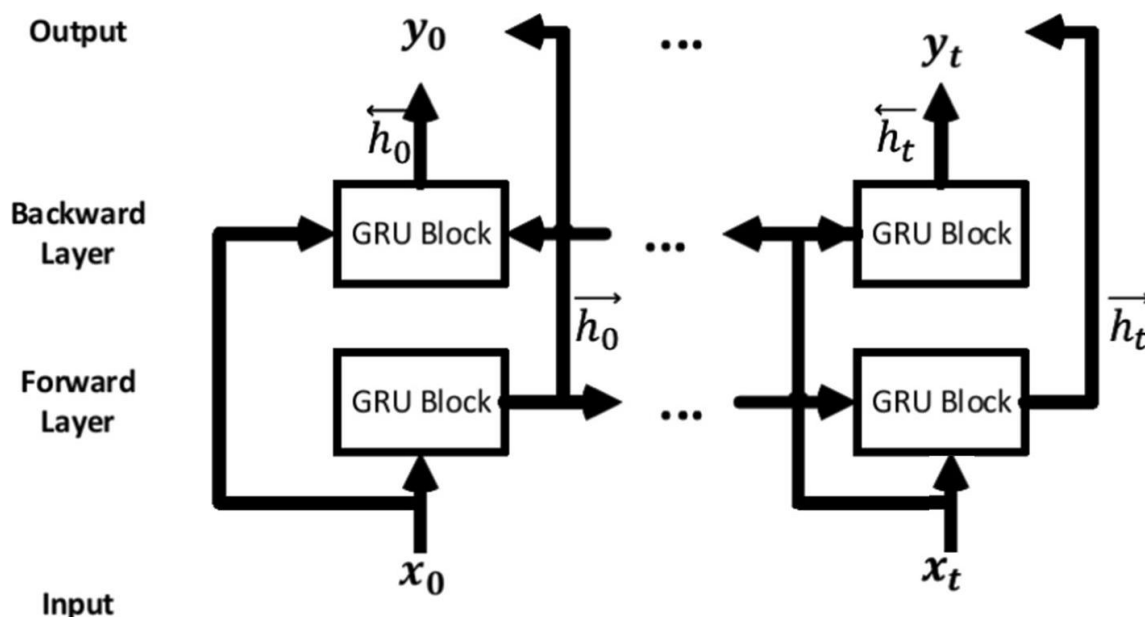


Рис. 4. Архитектура двунаправленной сети с блоками GRU

Повышение точности прогнозирования достигается за счет сочетания различных архитектур в гибридной модели, что позволяет решить проблемы нерегулярных закономерностей и тенденций, вызванных неравномерностью распределения данных (рис. 5) [6].

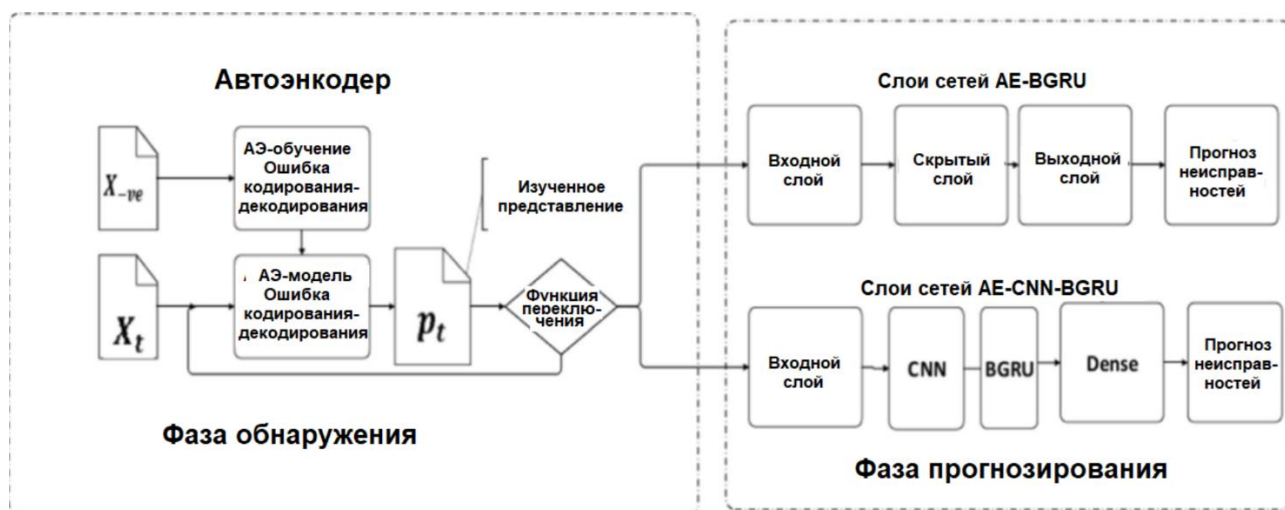


Рис. 5. Интегрированная модель обнаружения и прогнозирования редких отказов

В настоящее время не существует универсальной прогностической модели, ее выбор должен зависеть от конкретных характеристик и требований конкретной системы. Для сравнения и оценки моделей во многих случаях используется общедоступный набор данных турбовентиляторных двигателей C-MAPSS (Commercial Modular Aero-Propulsion System Simulation) от NASA. Анализ прогностической неопределенности и оценка точности прогнозов являются серьезной проблемой.

4. Планирование технического обслуживания авиационных двигателей на основе прогнозирования

В работе [7] предлагается использовать распределение вероятностей оставшегося срока полезного использования авиационных двигателей для оптимального планирования замены двигателей на основе обучения с подкреплением. $p_{k,t}$ – предполагаемая вероятность того, что оставшийся срок полезного использования двигателя меньше или равен k циклам при x_t :

$$p_{k,t} = P(R_t \leq k | x_t) \text{ для } k \in \{1, \dots, D\}, \quad (7)$$

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

Состоянием s_t является распределение вероятностей $p_{k,t}$ для следующих D летних циклов:

$$s_t = [p_{1,t}, \dots, p_{D,t}]. \quad (8)$$

Агенту доступны следующие действия:

$$a_t = \begin{cases} k, & 0 < k \leq D & \text{Заменить двигатель в цикле } k \\ M, & M > D & \text{Не заменять двигатель} \end{cases}. \quad (9)$$

Награда агента r_t на шаге t определяется по формуле:

$$r_t = \begin{cases} -c_{sch}(k), & \text{если } (k - 1 < a_t \leq k) \& (\rho_t > k) \\ -c_{uns}, & \text{если } (k - 1 < a_t \leq k) \& (\rho_t \leq k) \\ -c_{uns}, & \text{если } (a_t > D) \& (\rho_t \leq D) \\ 0, & \text{если } (a_t > D) \& (\rho_t > D) \end{cases}, \quad (10)$$

где, $c_{uns} > c_0$ – стоимость внеплановой замены,

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

С помощью выбора действия a_t в состоянии s_t на основе стратегии $\pi(a_t|s_t)$ агент стремится максимизировать долгосрочное вознаграждение:

$$J(\pi) = \sum_t \mathbb{E}_{(s_t, a_t) \sim \rho_\pi} [\gamma^t r_t(s_t, a_t)], \quad (11)$$

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

Определение оптимального шага для замены двигателя при помощи обучения с подкреплением позволит уменьшить количество внеплановых мероприятий по техническому обслуживанию и снизить затраты на техническое обслуживание.

5. Заключение

Переход к прогнозному техническому обслуживанию, основанному на данных бортовых датчиков мониторинга состояния авиационных двигателей для оценки оставшегося срока их полезного использования, позволит предвидеть сбои и оптимизировать выполнение задач по техническому обслуживанию.

Для внедрения прогнозного технического обслуживания необходимо преодолеть ряд серьезных проблем [8].

- Совместимость со старыми самолетами из-за несоответствия ранее существовавших бортовых систем и протоколов передачи данных.
- Необходимость использования стандартизованных форматов данных и протоколов связи.
- Обеспечение кибербезопасности при передаче данных.
- Необходимость соблюдения строгих стандартов безопасности и надежности при внедрении новых технологий в авиационную отрасль.
- Учет человеческого фактора, в том числе необходимость обучения персонала.
- Тщательный учет финансовых последствий инвестиций в прогнозное техническое обслуживание.

На основе проведенного обзора литературы можно сделать вывод, что, учитывая характер данных мониторинга авиационного двигателя, тенденция оценки оставшегося срока полезного использования и прогнозирования отказов авиационного двигателя смещается от традиционных методов машинного обучения в сторону глубокого обучения нейронных сетей. Основными проблемами являются неразмеченность и несбалансированность наборов данных для анализа. В настоящее время предлагается большое число различных методов и алгоритмов глубокого обучения нейронных сетей для диагностики состояния авиационных двигателей и прогнозирования оставшегося срока их полезного использования, в частности с использованием автоэнкодеров для выявления редких сбоев и сверточных или рекуррентных нейронных сетей с ячейками LSTM или GRU для прогнозирования возникновения следующего сбоя. В отечественной литературе работ, посвященных методам глубокого обучения для диагностики состояния авиационных двигателей и прогнозирования оставшегося срока их полезного использования, существенно меньше.

Одной из важных задач прогнозного обслуживания является интеграция полученных прогнозов оставшегося срока полезного использования авиационных двигателей в планирование технического обслуживания. Заслуживает внимания метод планирования технического обслуживания авиационных двигателей на основе глубокого обучения с подкреплением с использованием вероятностных прогнозов.

В рассмотренной области проводится значительный объем серьезных исследований, однако они прошли относительно ограниченный период разработки. Необходимы дальнейшие исследования для эффективного решения проблем, возникающих в реальных ситуациях прогнозного технического обслуживания авиационных двигателей.

Литература

1. *Kingsley-Jones M.* Airbus sees big data delivering “zero- AOG” goal within 10 years. – Flightglobal. 2017.
2. *Badea VE, Zamfiroiu A, Boncea R.* Big Data in the Aerospace Industry. // *Inf Econ.* – 2018. – 22(1/2018). – P. 17–24.
3. *Сай Ван Квонг* Глубокие нейронные сети для предсказательного технического обслуживания. // *Моделирование, оптимизация и информационные технологии.* – 2019. – № 7(4).
4. *Stanton I, Munir K., Ikram A., El-Bakry M.* Predictive Maintenance Analytics and Implementation for Aircraft: Challenges and Opportunities // *Systems Engineering.* – 2023. – Vol. 26. Issue. 2. – P. 216–237. DOI: 10.1002/sys.21651.
5. *Fu, S.; Zhong, S.; Lin, L.; Zhao, M.* A re-optimized deep auto-encoder for gas turbine unsupervised anomaly detection. // *Eng. Appl. Artif. Intell.* – 2021. – 101, 104199.
6. *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(4). – P. 2991-3009.
7. *Lee J., Mitici, M.* Deep Reinforcement Learning for Predictive Aircraft Maintenance Using Probabilistic Forecast of Remaining Useful Life // *Reliability and System Safety.* – 2023. – Vol. 230(1). 108908. DOI: 10.1016/j.ress.2022.108908.
8. *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.