

ПЕРСПЕКТИВНЫЕ ПОДХОДЫ К ПРОГНОЗИРОВАНИЮ ОСТАВШЕГОСЯ СРОКА ПОЛЕЗНОГО ИСПОЛЬЗОВАНИЯ АВИАЦИОННЫХ ДВИГАТЕЛЕЙ[#]

Е. Л. Кулида*, В. Г. Лебедев**

Институт проблем управления им. В.А. Трапезникова РАН, г. Москва

*✉ elena-kulida@yandex.ru, **✉ lebedev-valentin@yandex.ru

Аннотация. Представлен обзор литературы, посвященной диагностике и прогнозированию оставшегося срока полезного использования авиационных двигателей на основе глубокого обучения. Приведена формальная постановка задачи оценки оставшегося срока полезного использования. Рассмотрены основные архитектуры глубоких нейронных сетей, применяемые для обнаружения редких сбоях и прогнозирования следующих сбоях на основе данных мониторинга авиационных двигателей. Рассмотрено извлечение информативных признаков с помощью автоэнкодеров. Приводится структура ячеек долгой кратковременной памяти и механизма внимания, применяемых в глубоких нейронных сетях для прогнозирования оставшегося срока полезного использования. Рассматривается задача интеграции прогноза оставшегося срока полезного использования в планирование технического обслуживания на основе обучения с подкреплением.

Ключевые слова: диагностика авиационных двигателей, прогнозное техническое обслуживание, прогнозирование оставшегося срока полезного использования, глубокое обучение.

ВВЕДЕНИЕ

Стратегию технического обслуживания можно разделить на три основных типа, а именно на реактивное, плановое и прогнозное обслуживание. Реактивное обслуживание выполняется после возникновения неисправности оборудования. Отказы авиационных двигателей могут привести к большим экономическим потерям, экологическому ущербу и даже, в крайних случаях, к авариям [1]. Плановое обслуживание – это стратегия, при которой оборудование обслуживается через определенные промежутки времени по заранее определенному графику, что часто приводит к ненужным работам и связанным с ними затратам. Прогнозное обслуживание – это стратегия организации мероприятий по техническому обслуживанию в соот-

ветствии с состоянием целевых компонентов или систем и прогнозом развития отказов во время эксплуатации. Прогнозное обслуживание – это перспективная технология технического обслуживания, которая позволит добиться повышения надежности и безопасности при одновременном снижении затрат на техническое обслуживание путем оценки текущего состояния работоспособности в процессе эксплуатации и прогнозирования оставшегося срока полезного использования (англ. *Remaining Useful Life, RUL*).

Стратегия прогнозного обслуживания применяется все шире и шире, поскольку при таком обслуживании сводится к минимуму простой оборудования и ресурсы могут использоваться максимально эффективно. Таким образом, надежные инструменты прогнозирования и управления техническим состоянием становятся все более востребованными. Получение упреждающей оценки технического состояния и прогнозирование оставше-

[#] Исследование частично выполнено за счет гранта Российского научного фонда (проект № 23-19-00464).

гося срока полезного использования систем и/или оборудования, подвергающихся старению или деградации, признано очень важным для повышения эффективности эксплуатации летательных аппаратов (ЛА) и оптимизации их технического обслуживания [2]. Двигатель является сердцем самолета и причиной примерно 60 % всех отказов, поэтому диагностика и прогнозирование оставшегося срока полезного использования авиационных двигателей имеют решающее значение для обеспечения безопасной эксплуатации ЛА и разработки планов технического обслуживания [3].

Техническое обслуживание по состоянию на основе актуальной информации, получаемой в процессе эксплуатации двигателя, осуществляется с целью своевременного обнаружения и предотвращения потенциальных неисправностей и дорогостоящего незапланированного технического обслуживания. В научной литературе имеется много исследований по разработке моделей для прогнозирования оставшегося срока полезного использования авиационных двигателей [4–7]. В зависимости от применяемых подходов предлагаемые методы прогнозирования разделяются на три группы: основанные на физических моделях деградации двигателя, на основе обработки и анализа многомерных данных мониторинга работы двигателя и гибридные [8]. Использование моделей деградации требует понимания фундаментальных физических принципов работы и механизмов отказов двигателя [9, 10]. Учитывая сложность взаимосвязи между показаниями датчиков и оставшимся сроком полезного использования двигателя, реализовать адекватную математическую модель деградации очень сложно. Поэтому основные исследования сосредоточены на методах, базирующихся на данных, которые имеют преимущество при отсутствии точной математической модели или подробных экспертных знаний о двигателе, а также предоставляют возможность определения неизвестных аномалий [11]. Подход, основанный на обработке и анализе данных, предполагает диагностику двигателя с помощью собранных исторических эксплуатационных данных для прогнозирования будущего состояния [12–15]. Существенным недостатком этого подхода является отсутствие интерпретируемости моделей [16]. Для авиационных двигателей, которые используются в отрасли с высоким уровнем опасности, очень важно обеспечить интерпретируемость моделей при сохранении точности прогнозирования. Для того чтобы понять, почему традиционные модели машинного обучения работают хуже, чем модели глубокого обучения, авторы применяют метод LIME (*Local*

Interpretable Model-agnostic Explanations) для объяснения моделей «черного ящика» [17]. В статье [18] предлагается интерпретируемый метод прогнозирования оставшегося срока полезного использования авиационных двигателей в сложных условиях эксплуатации с использованием пространственно-временных характеристик, включающий модуль интерпретации на основе гибридного механизма внимания для вывода интерпретируемых прогнозов.

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 [19].

Методы, основанные на данных, подразделяются на контролируемые, если наборы данных содержат метки классов, и неконтролируемые, использующие неразмеченные данные. Поскольку получение размеченных данных требует больших затрат времени и усилий, в последнее время для прогнозирования оставшегося срока полезного использования в основном применяются неконтролируемые или полуконтролируемые методы, в которых данные размечены частично. Подходы к прогнозированию на основе данных включают классические методы машинного обучения, такие как метод случайного леса, метод k ближайших соседей, метод опорных векторов и его варианты, байесовские методы, градиентный бустинг и др. В последнее время все больше исследуются алгоритмы глубокого обучения с использованием автоэнкодеров, сверточных нейронных сетей, рекуррентных нейронных сетей (англ. *Recurrent Neural Networks*, RNN) с ячейками долгой краткосрочной памяти (англ. *Long Short-Term Memory*, LSTM) и блокируемой рекуррентной памяти (англ. *Gated Recurrent Unit*, GRU) [20]. Двухнаправленная LSTM (Bi-LSTM) [21] может использовать входную информацию большого радиуса действия в двух направлениях как из прошлого, так и из будущего контекста. Объединение Bi-LSTM путем соединения выхода нижнего уровня со входом более высокого уровня дает глубокую Bi-LSTM [22]. Выбор из большого количества вариантов конкретного алгоритма, который может дать хорошие результаты для конкретной ситуации, является непростой задачей. Сравнению разных подходов к решению проблемы и выбору оптимального из них посвящено много исследований [23].



Традиционные методы машинного обучения требуют извлечения информативных признаков и уменьшения размерности данных разработчиком, неудачная предобработка данных обычно приводит к неудовлетворительной производительности. Алгоритмы глубокого обучения способны автоматически извлекать абстрактные представления функций высокого уровня из огромных объемов необработанных данных датчиков без необходимости разработки функций, что вдохновляет все большее число ученых применять эти методы для прогнозирования оставшегося срока полезного использования [24]. При обработке больших объемов данных нейронная сеть справляется с выделением признаков гораздо лучше, чем человек [25]. В последнее время было показано, что модели глубокого обучения обеспечивают очень высокую производительность при обучении на больших наборах данных благодаря их способности сочетать автоматическое извлечение признаков с обучением [26].

Эксплуатационные данные, генерируемые датчиками технического состояния ЛА, крайне несбалансированы, поскольку отказы двигателей происходят во время полетов очень редко и данные смещены в сторону нормальной работы. В этом случае необходимы специальные методы анализа, способные противодействовать дисбалансу данных. В работах [27, 28] представлен метод обнаружения редких отказов для прогнозируемого обслуживания самолетов с применением подхода глубокого гибридного обучения на основе несбалансированного набора данных. Предлагаемая модель включает два этапа: на первом используется автоэнкодер для обнаружения редких сбоев, а на втором – сверточная нейронная сеть с двунаправленными управляемыми рекуррентными блоками Vi-GRU для прогнозирования следующего возникновения сбоя. Утверждается, что модель справляется с нерегулярными закономерностями и тенденциями; это помогает решить проблему несбалансированных данных. Модель состоит из глубоких нейронных сетей, автоматического кодировщика для обнаружения сбоев и двунаправленных сетей с вентилируемыми рекуррентными блоками в сочетании со сверточными нейронными сетями для изучения взаимосвязей между переменными.

В РФ технология предсказательного моделирования, в том числе для прогнозного технического обслуживания авиационных двигателей, успешно развивается в Сколковском институте науки и технологий и в использующей программное обеспечение собственной разработки компании DATADVANCE [29].

1. МОНИТОРИНГ И ДИАГНОСТИКА АВИАЦИОННЫХ ДВИГАТЕЛЕЙ НА ОСНОВЕ ГЛУБОКИХ НЕЙРОННЫХ СЕТЕЙ

1.1. Постановка задачи оценки оставшегося срока полезного использования

Во время полетов современных самолетов генерируются большие объемы данных мониторинга состояния, в частности, при работе двигателя Боинга 787 непрерывно контролируется около тысячи параметров [30], которые являются основой для оценки оставшегося срока полезного использования и прогнозного технического обслуживания.

Цель прогнозирования оставшегося срока полезного использования заключается в том, чтобы оценить промежуток времени между текущим моментом и временем выхода двигателя из строя. Задача оценки оставшегося срока полезного использования может быть сформулирована двумя способами: при первом способе задача заключается в определении того, существует ли вероятность отказа в течении следующих n временных шагов – задача многоклассовой классификации. Второй способ заключается в предсказании оставшегося времени работы до отказа, т. е. количества рабочих циклов до выхода двигателя из строя, – задача регрессии.

Рассматривается сценарий [31], в котором состояние работоспособности набора экземпляров инженерной системы (обозначаемых U) отслеживается и сохраняется в мультисенсорных данных до конца оставшегося срока полезного использования. Для каждого экземпляра системы $u \in U$ собранные мультисенсорные данные представляют собой многомерный временной ряд, обозначаемый $X^{(u)} = \{x_1^{(u)}, x_2^{(u)}, \dots, x_L^{(u)}\}$. Здесь L – последний жизненный цикл системы; $x_t \in \mathbb{R}^n$ – вектор размерности n , соответствующий показаниям n датчиков в момент времени t : $x_t^{(u)} = [x_{ij}^{(u)}]_{j=1}^n$. Набор показаний датчика до отказа $\{X^{(u)} | u \in U\}$. Цель – построить нелинейное отображение следующим образом:

$$f_{\Theta_p} : X^{(u)}(t, l) \rightarrow R_t^{(u)}, t \in \{l, l+1, \dots, L^{(u)}\},$$

где Θ_p – набор параметров, которые определяют в процессе обучения модели; $X^{(u)}(t, l)$ – подпоследовательность длины l для временного ряда $X^{(u)}$, начиная с момента времени $t - l + 1$, т. е.

$$X^{(u)}(t, l) = \{x_{t-l+1}^{(u)}, x_{t-l+2}^{(u)}, \dots, x_t^{(u)}\},$$

$R_t^{(u)}$ – значение оставшегося времени работы до отказа в момент времени t . Процедуры построения модели выполняются в автономном режиме. Как только модель нелинейного отображения хорошо обучена, ее можно использовать для прогнозирования оставшегося срока полезного использования для других экземпляров системы U^* в реальном времени. Для каждой системы $u^* \in U^*$ прогнозируемый оставшийся срок полезного использования определяется выражением

$$\hat{R}_t^{(u^*)} = f_{\Theta_p} \left(x_{t-l+1}^{(u^*)}, x_{t-l+2}^{(u^*)}, \dots, x_t^{(u^*)} \right),$$
$$t \in \{l, l+1, \dots, L^{(u^*)}\}.$$

С помощью обученной модели можно оценить оставшийся срок полезного использования рассматриваемой системы при помощи исторических и текущих данных датчиков.

Для сравнения различных предлагаемых моделей и методов и оценки их эффективности проводятся вычислительные эксперименты, для которых во многих случаях используется общедоступный набор данных турбовентиляторных двигателей C-MAPSS (*Commercial Modular Aero-Propulsion System Simulation*) от NASA [32, 33]. Этот популярный набор содержит данные, которые состоят из многовариантных временных данных от 21 датчика, полученных с помощью программы моделирования модульных авиационных двигательных установок. Набор данных состоит из четырех подгрупп, каждая из них разделена на обучающую выборку, в которой записаны данные мониторинга условий работы до отказа турбовентиляторных двигателей, и тестовую выборку, завершающуюся в определенной точке перед полным отказом. Цель – спрогнозировать оставшийся срок полезного использования для тестовых данных. Данные мониторинга состояния представляют собой данные многомерных временных рядов, имитирующих поведение авиационных двигателей. Данные мониторинга состояния загрязнены шумом, а начальное состояние износа и производственные отклонения турбовентиляторных двигателей неизвестны, что затрудняет точное прогнозирование оставшегося срока полезного использования [34].

В 2021 г. был опубликован новый набор данных о деградации турбовентиляторного двигателя – N-CMAPSS [35]. По сравнению с предыдущим набором данных моделирования деградации тур-

бовентиляторного двигателя N-CMAPSS обеспечивает траектории работы до отказа для небольшого парка авиационных двигателей в реалистичных условиях полета.

Для оценки модели регрессии обычно используется среднеквадратичная ошибка

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (e_i^2)},$$

где e_i – это разность между прогнозируемым и истинным значениями оставшегося срока полезного использования. Точность модели классификации – это вероятность того, что класс будет предсказан правильно.

В работе [36] на основе данных C-MAPSS сравниваются методы регрессии и классификации с помощью методов машинного обучения: случайного леса (англ. *Random Forest*, RF), опорных векторов (англ. *Support Vector Machine*, SVM) и глубокого обучения на основе LSTM для оценки оставшегося срока полезного использования. Оценка RMSE для метода регрессии такова: для RF – 19,98, для LSTM – 20,91, для SVM – 20,512. Метод RF является лучшим при реализации метода регрессии. Однако результаты исследования показывают, что метод классификации для этой задачи работает лучше и быстрее, чем метод регрессии. Оценка точности метода классификации для LSTM – 98,7 %, для SVM – 95,6 % и для RF – 90,3 %. Метод классификации на основе LSTM точнее и быстрее, по сравнению с другими методами в этом исследовании, при расчете оставшегося срока полезного использования для прогнозного обслуживания авиационного двигателя.

В работе [37] исследуется точность различных моделей машинного обучения и глубокого обучения для прогнозирования технического обслуживания авиационного двигателя. Здесь для прогнозирования отказа авиационного двигателя из набора данных C-MAPSS в течение заранее определенного количества циклов используются методы глубокого обучения (LSTM, Bi-LSTM, RNN, Bi-RNN GRU) и традиционные методы машинного обучения (метод случайного леса, k ближайших соседей, наивный байесовский классификатор и градиентный бустинг). Высокая точность 97,8, 97,14 и 96,42 % достигается с помощью GRU, Bi-LSTM и LSTM соответственно, что означает способность моделей на ранней стадии прогнозировать необходимость технического обслуживания авиационных двигателей.

Глубокое обучение обеспечивает также существенное повышение производительности по сравнению с традиционными методами [38].



1.2. Извлечение признаков с помощью автоэнкодеров

Данные мониторинга двигателей сложны и многомерны, поэтому для неконтролируемого обнаружения аномалий необходимо извлечь из них высокоуровневые признаки. Для извлечения признаков из сложных и многомерных неразмеченных наборов данных в последнее время часто используются автоэнкодеры (*autoencoders*). Автоэнкодер состоит из двух частей: кодера и декодера. Входной вектор $x \in R^n$ с помощью функции кодирования отображается в скрытое представление $h \in R^m$:

$$h = f_{\theta}(x) = S_1(Wx + b),$$

$$S_1(x) = \max(0, x),$$

где W – весовая матрица размера $m \times n$; $b \in R^m$ – вектор смещения; $S_1(\cdot)$ – функция активации ReLU.

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

$$z = g_{\theta'}(h) = S_2(W'h + b'),$$

$$S_2(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}},$$

где W' – весовая матрица размера $n \times m$; b' – вектор смещения; $S_2(\cdot)$ – функция активации tanh.

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

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

где L – квадратичная ошибка; V – 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:

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

где K – размер мини-пакета.

Для построения глубокой многоуровневой нейронной сети предыдущий скрытый слой используется в качестве входных данных для следующего слоя. Многомерные данные преобразуются

в низкоразмерные путем обучения многослойной нейронной сети с небольшим центральным слоем для восстановления многомерных входных векторов. В работе [39] показано, что автоэнкодеры в качестве инструмента для уменьшения размерности данных работают намного лучше, чем метод главных компонент. Для точной настройки весов в сетях автоэнкодеров применяется градиентный спуск. Утверждается, что уменьшение размерности с помощью глубоких автоэнкодеров будет очень эффективным при условии, что компьютеры достаточно быстрые, наборы данных достаточно большие, а начальные веса достаточно близки к хорошему решению.

Однако традиционные глубокие автоэнкодеры плохо справляются с несбалансированными данными, в то время как данные мониторинга двигателей крайне несбалансированы, поскольку данных о нормальной работе существенно больше, чем об аномальной, а образцов некоторых видов аномальной работы вообще может не быть. В работе [40] представлен оптимизированный глубокий автоэнкодер для обнаружения аномалий работы газовых турбин на основе неразмеченных данных эксплуатации. В его 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, а 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 (рис. 1) [40]. После этого изученные при помощи оптимизированного автоэнкодера ошибки реконструкции и скрытые функции

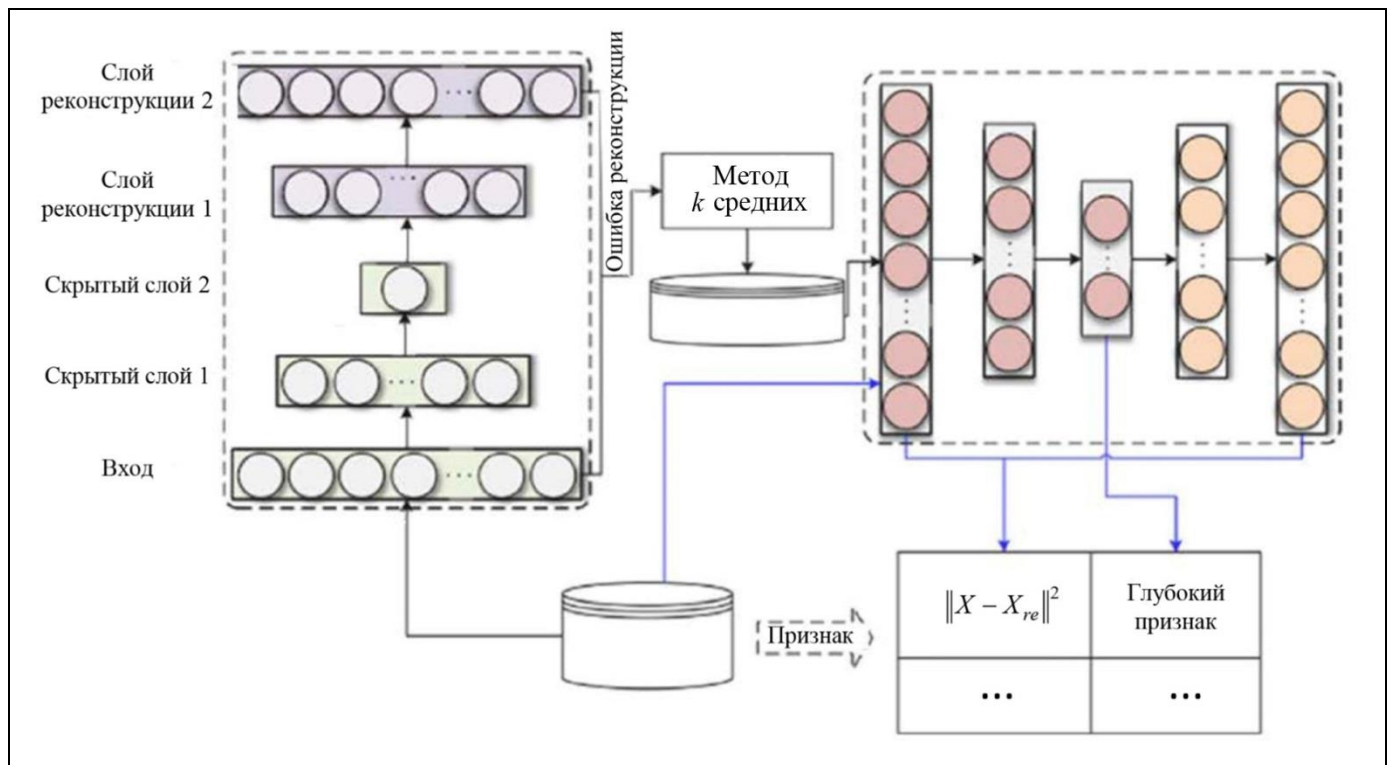


Рис. 1. Оптимизированный глубокий автоэнкодер

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 механизмов на обнаружение аномалий и эффективно решает проблему недостаточного обучения, вызванную недостаточным количеством образцов для одного двигателя.

1.3. Модели на основе сверточных нейронных сетей

Одним из широко применяемых подходов глубокого обучения являются сверточные нейронные сети. Популярность сверточных нейронных сетей объясняется их способностью читать, обрабатывать и извлекать наиболее важные характеристики двумерных данных, что способствует высокой производительности, особенно для классификации изображений. Данные мониторинга авиационных двигателей, представляющие собой многомерные временные ряды длиной M и шириной N (длина M – это количество временных шагов в данных, а ширина N – это количество переменных в многомерном временном ряду), можно использовать в качестве входных данных для сверточных нейронных сетей, как показано на рис. 2 [28].

При преобразовании данных временных рядов одномерное сверточное ядро имеет такую же ши-

рину N . Ядро движется сверху вниз, выполняя свертки до конца ряда. Элементы временного ряда, охватываемые в данный момент времени (окно), умножаются на элементы сверточного ядра, результаты умножения складываются и к этой сумме применяется нелинейная функция активации. Полученное значение становится элементом следующей новой отфильтрованной серии. Затем ядро переходит к созданию следующего значения. Максимальное объединение применяется к каждой отфильтрованной серии векторов. Выбирается наибольшее значение вектора, которое используется в качестве входных данных для обычного полносвязного слоя. Стандартная структура искусственной нейронной сети обычно состоит из входного слоя, одного или нескольких скрытых слоев и выходного слоя. Количество скрытых слоев и нейронов, используемых для достижения оптимального решения, варьируется в зависимости от ситуации и выбирается путем проб и ошибок.

В работах [41, 42] рассматривается регрессионный подход на основе глубокой сверточной нейронной сети для оценки оставшегося срока полезного использования, фильтры свертки и объединения применяются во временном измерении к данным многоканального датчика для систематического автоматического изучения характеристик по необработанным сигналам. В статье [43] предлагается многомасштабная глубокая сверточная

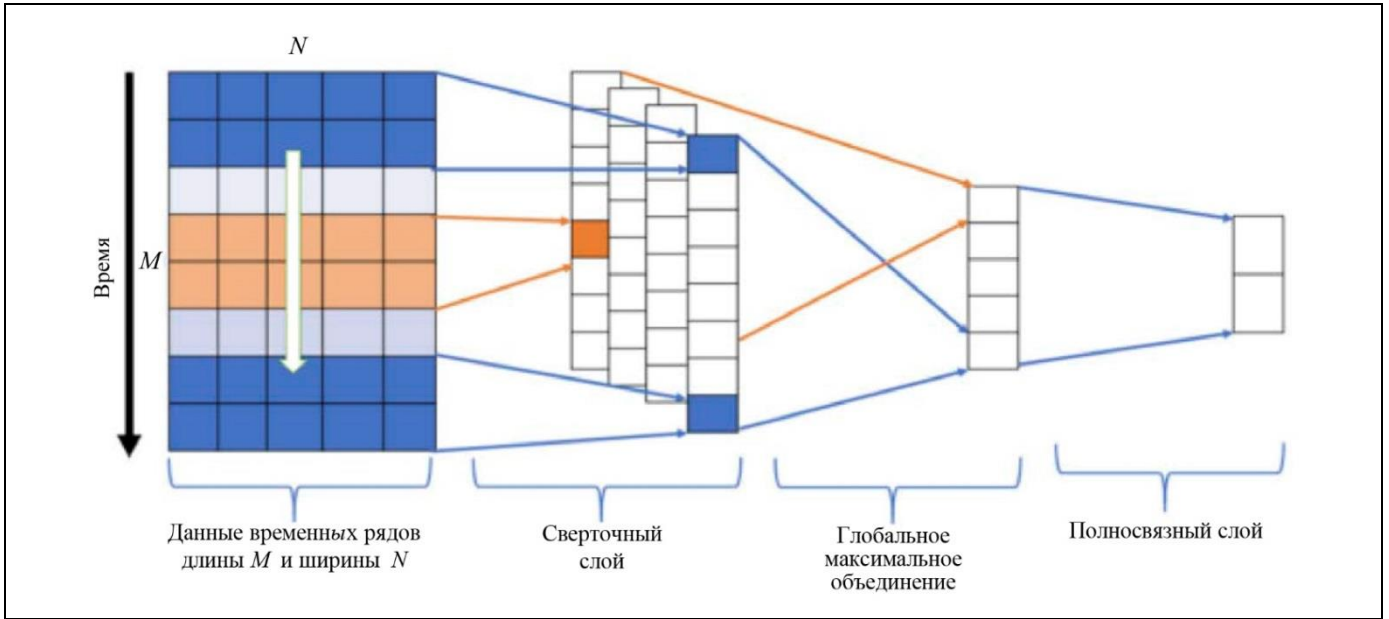


Рис. 2. Сверточная сеть для данных временного ряда

нейронная сеть, которая имеет различные сверточные фильтры разных размеров для извлечения более подробных характеристик для оценки оставшегося срока полезного использования. Предлагаемый подход оценивается и сравнивается с другими методами (глубокой нейронной сетью, рекуррентной нейронной сетью, сетью с LSTM и глубокой сверточной нейронной сетью) на наборе данных C-MAPSS. В публикации [44] отмечается, что согласно проведенному моделированию для задачи многоклассовой классификации на основе доступных наборов данных NASA, подход с трансформацией временных рядов в изображения с последующим применением сверточной нейронной сети показал приемлемые результаты при прогнозировании оставшегося срока службы авиационных двигателей. К дальнейшему улучшению результатов может привести увеличение количества данных для обучения модели.

1.4. Модели на основе рекуррентных нейронных сетей

Рекуррентные нейронные сети – это нейронные сети, содержащие обратные связи. Такие сети хорошо подходят для обработки временных рядов. Для входной временной последовательности $x = (x_1, \dots, x_r)$ рекуррентная нейронная сеть дает скрытую последовательность векторов $h = (h_1, \dots, h_r)$ и в результате – последовательность выходных векторов $y = (y_1, \dots, y_r)$. Уравнения итерационного расчета имеют следующий вид во временном диапазоне $t = 1, T$:

$$h_t = H(W_{xh}x_t + W_{hh}h_{t-1} + b_h),$$

$$y_t = W_{hy}h_t + b_y,$$

где W – весовые матрицы; b – векторы смещения; H – функция активации, которая обычно является сигмоидной функцией.

Обычная рекуррентная нейронная сеть представляет собой цепочку повторяющихся модулей, которые используют только предыдущие входные данные. В двунаправленных рекуррентных нейронных сетях (англ. *Bidirectional Recurrent Neural Networks, BRNN*) [45] последовательность входных данных подается в два скрытых слоя, как показано на рис. 3. Двунаправленный подход обеспечивает возможность использования как прошлого, так и будущего контекста.




Рис. 3. Двунаправленная рекуррентная нейронная сеть

В работе [46] предлагается метод ансамбля глубоких двунаправленных рекуррентных нейронных сетей для прогнозирования оставшегося срока полезного использования авиационного двигателя. Предлагаемый метод проверен с использованием наборов данных C-MAPSS. Результаты эксперимента показывают, что предложенный метод достигает высокой производительности.

При обучении на длинных последовательностях данных в рекуррентной нейронной сети может возникнуть проблема уменьшения (исчезновения) или стремительного увеличения (взрыва) градиента. Кроме того, с помощью рекуррентной нейронной сети не удастся выявлять долгосрочные последовательные зависимости. Важной разновидностью рекуррентных нейронных сетей являются сети, в которых используются ячейки LSTM и GRU – благодаря их структуре информация может сохраняться в течение длительного времени.

1.5. Модели для изучения долгосрочных зависимостей на основе LSTM

Блок LSTM [47] – это специально разработанная ячейка памяти, в которую добавлена система фильтров, ограничивающих информационный поток. Функция фильтров обычно представляет собой сигмоидную функцию, значение выходного сигнала которой находится в диапазоне от 0 до 1 и определяет, какую долю информации следует пропустить. Структура LSTM из работы [48] показана на рис. 4.

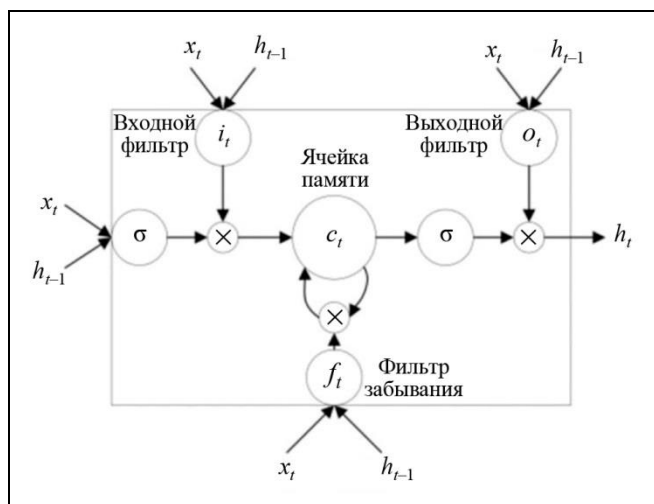


Рис. 4. Ячейка памяти LSTM

Функции фильтров описываются следующими уравнениями:

$$i_t = \sigma(W_{xi}x_t + W_{hi}h_{t-1} + b_i),$$

$$f_t = \sigma(W_{xf}x_t + W_{hf}h_{t-1} + b_f),$$

$$o_t = \sigma(W_{xo}x_t + W_{ho}h_{t-1} + b_o),$$

$$c_t = f_t \odot c_{t-1} + i_t \odot \tanh(W_{xc}x_t + W_{hc}h_{t-1} + b_c),$$

$$h_t = o_t \odot \tanh c_t,$$

где i, f, o – соответственно входной фильтр, фильтр забывания и выходной фильтр; c обозначает ячейку памяти; h обозначает скрытую векторную последовательность; σ – сигмоидная функция активации; \odot – поэлементное умножение векторов. Уравнения трех элементов имеют одинаковую структуру, однако весовые матрицы имеют разные значения. Входной фильтр i управляет информацией, поступающей в ячейку памяти c_t . Фильтр забывания f управляет информацией последней ячейки памяти c_{t-1} , накапливаемой в текущей ячейке памяти c_t . Выходной фильтр o влияет на информацию, поступающую в скрытое состояние h_t . Система фильтров позволяет избежать проблем с исчезновением или взрывом градиента.

Глубокие архитектуры позволяют модели изучать необработанные входные данные высокого уровня и находить долгосрочные зависимости в последовательностях, поэтому они хорошо подходят для прогнозирования оставшегося срока полезного использования. Многие исследователи предлагают свои модели на основе LSTM для прогнозирования отказов авиационных двигателей и, сравнивая их с более ранними подходами, утверждают, что методы на основе LSTM улучшают прогнозирование оставшегося срока полезного использования авиационных двигателей и обеспечивают лучшую производительность [3, 49, 50]. В работе [51] предложен метод, который сочетает в себе одномерную сверточную сеть с полным сверточным слоем и сеть с LSTM для прогнозирования оставшегося срока полезного использования турбовентиляторных двигателей. Для решения проблемы несбалансированных данных в статье [52] представлена общая структура прогнозирования неисправностей, включающая методы обучения функций автоэнкодера на основе LSTM. Проблемы, связанные с воздействием шума в сложных операциях и различных аномальных условиях, решаются в работе [53] на основе двухканальной модели нейронной сети LSTM. В публикации [54] для решения проблемы прогнозирования оставшегося срока полезного использования представлена модель, объединяющая систему широкого обучения для извлечения признаков и LSTM для обработки информации временных рядов. В статье [55]



рассматривается двунаправленный управляемый рекуррентный блок с ячейками GRU, которые предназначены для решения проблемы исчезновения градиента. 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.

1.6. Механизм внимания

Входные характеристики, предоставляемые несколькими датчиками, по-разному влияют на деградацию системы. Результаты прогнозирования

оставшегося срока полезного использования имеют разные зависимости от входных данных на разных временных шагах, а временная корреляция может меняться с изменением степени деградации. Таким образом, необходимо сосредоточиться на более важной информации среди многочисленных входных данных, чтобы получить удовлетворительную точность прогнозирования. Руководствуясь этим фактом, исследователи разрабатывают механизмы внимания как важную часть модели прогнозирования для выбора наиболее релевантных входных функций, а также для адаптивного извлечения временной корреляции.

Как показано на рис. 5 из работы [31], механизм внимания к признакам в основном состоит из многослойного перцептрона и слоя softmax.

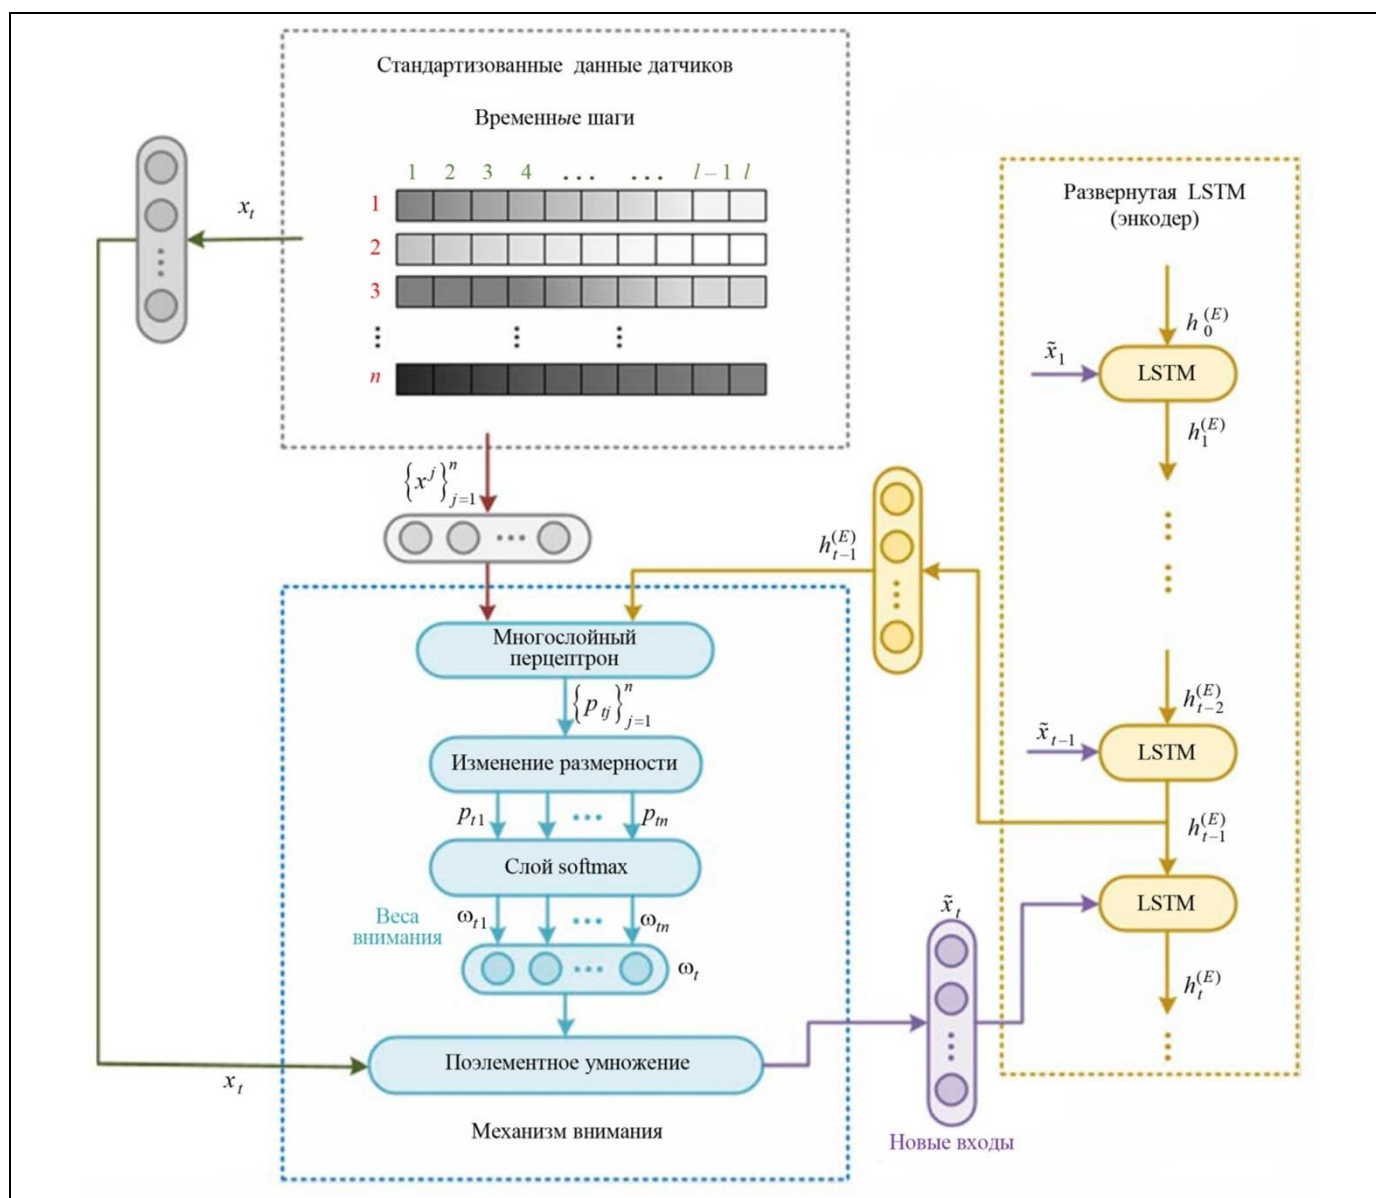


Рис. 5. Механизм внимания к признакам

На каждом временном шаге каждый входной признак оценивается с помощью многослойного перцептрона, обращаясь к предыдущему скрытому состоянию кодера:

$$p_{ij} = v_p^T \tanh \left(W_p \left[h_{t-1}^{(E)}; x^j + b_p \right] \right),$$

где p_{ij} представляет собой оценку внимания данных j -го датчика в момент времени t ; $x^j = [x_{1j}, x_{2j}, \dots, x_{mj}]^T \in \mathbb{R}^l$ – временной ряд j -го датчика; $h_{t-1}^{(E)}$ – предыдущее скрытое состояние кодера. Здесь m – количество скрытых нейронов кодера; $v_p \in \mathbb{R}^l$, $W_p \in \mathbb{R}^{l \times (m+l)}$ и $b_p \in \mathbb{R}^l$ – весовые матрицы и вектор смещения, которые необходимо определить в процессе обучения.

Затем вес внимания каждой входной функции можно определить с помощью слоя softmax:

$$\varpi_{ij} = \frac{\exp(p_{ij})}{\sum_{j=1}^n \exp(p_{ij})},$$

где ϖ_{ij} – вес внимания данных j -го датчика в момент времени t , который отражает важность данных j -го датчика. Используя веса внимания, можно взять выборку входных данных на основе важности с помощью операции

$$\tilde{x}_t = \varpi_t \odot x_t,$$

где \tilde{x}_t соответствует вновь вычисленному входному сигналу в момент времени t ; $[\varpi_{ij}]_{j=1}^n = [\varpi_{t1}, \varpi_{t2}, \dots, \varpi_{tn}] \in \mathbb{R}^n$ – вектор веса внимания в момент времени t .

В работе [56] предлагается модифицированный метод LSTM с механизмом внимания, который улучшает прогнозирование оставшегося срока полезного использования авиационных двигателей. В публикации [57] для достижения более точных результатов прогнозирования сверточная сеть используется с механизмом внимания для сбора информации о долгосрочных временных рядах. В статье [24] для оценки оставшегося срока полезного использования авиационного двигателя предлагается архитектура, основанная на сверточной нейронной сети и механизме двойного внимания для придания большего веса более значимым характеристикам на критических временных этапах.

В работе [58] предложена архитектура глубокого обучения, называемая сетью дистанционного самовнимания, основанная на объединении исто-

рической информации и данных в реальном времени. В предлагаемом методе разработана функция расстояния для улучшения возможности извлечения признаков; объединение данных основано на рекуррентной нейронной сети. Эффективность метода для оценки оставшегося срока полезного использования проверена при помощи данных C-MAPSS. Утверждается, что метод превосходит типичные методы, основанные на сверточной нейронной сети или сети с LSTM, поскольку значение среднеквадратичной ошибки RMSE уменьшилось на 7,3 % ~ 25,3 %.

1.7. Модели на основе архитектуры трансформера

Многие представленные выше модели хорошо себя зарекомендовали при работе с данными моделирования C-MAPSS. Однако в новых работах вместо использования сверточных и рекуррентных нейронных сетей для оценки оставшегося срока полезного использования авиационного двигателя в реальных, а не моделируемых условиях полета предлагается использовать предложенную в 2017 г. архитектуру трансформера [59].

Этот вид нейросетевой архитектуры использует механизм многоголового самовнимания, который позволяет динамически оценивать важность различных элементов в последовательности и хорошо подходит для обработки последовательностей данных. Главное преимущество моделей на основе трансформеров заключается в их способности обрабатывать долгосрочные зависимости в последовательностях, преодолевая проблему исчезновения градиента, присущую рекуррентным сетям. Кроме того, эта архитектура позволяет обрабатывать входные последовательности параллельно.

В докладе [60] предлагается модель оценки оставшегося срока полезного использования турбовентиляторных двигателей, основанная на архитектуре трансформера. Для извлечения функций из входных данных переменной длины применяется механизм самовнимания с несколькими головками, позволяющий улавливать особенности каждого режима в реальных условиях полета. В работах [61, 62] двухаспектное самовнимание на основе трансформера предназначено для обеспечения детального понимания как временной динамики, так и вклада отдельных датчиков для реализации более полных возможностей прогнозирования оставшегося срока полезного использования турбореактивного двигателя. В статье [63] предлагается двухступенчатая структура иерархического трансформера для фиксации как временных, так и сенсорных переменных для прогнозирования и



используется иерархическая структура кодера – декодера для захвата временной информации в различных временных масштабах. В публикации [64] особое внимание уделяется надежности прогнозирования оставшегося срока полезного использования турбовентиляторных двигателей с учетом количественной оценки неопределенностей, связанных как с ошибкой модели, так и со случайностью в данных.

1.8. Сравнение методов прогнозирования оставшегося срока полезного использования авиационных двигателей

Для повышения точности прогнозирования предлагаются гибридные модели, построенные на основе сочетания различных архитектур, что позволяет решать проблемы нерегулярных закономерностей и тенденций, вызванных неравномерностью распределения данных.

В работах [63, 65] приводится сравнение различных методов прогнозирования оставшегося срока полезного использования авиационных двигателей. В таблице представлены оценки следующих методов:

- подход на основе глубокой сверточной нейронной сети (CNN) [41],
- сеть долгой краткосрочной памяти (LSTM) [66],
- двунаправленная сеть с долгой краткосрочной памятью (BiLSTM) [48],
- многоголовочная архитектура, использующая параллельные ответвления CNN последовательно с LSTM (*Multi-head CNN+LSTM*) [67],
- стролируемый сверточный трансформер (англ. *Gated Convolutional Transformer, GCT*) [68],
- модель, которая извлекает признаки данных на основе системы широкого обучения и использует LSTM для обработки временных рядов (B-LSTM) [54],

- трансформер на основе двухаспектного самовнимания (англ. *Dual-Aspect Self-attention Transformer, DAST*) [61],

- трансформер на основе двунаправленного LSTM автоэнкодера (BiLSTM-DAE Transformer) [65],

- двухэтапный иерархический трансформер на основе внимания (англ. *two-stage attention-based hierarchical Transformer, STAR*) [63].

Для оценки эффективности методов используются две метрики: среднеквадратичная ошибка RMSE и оценка Score.

Оценка эффективности Score вводит меньший штраф, если $y_i < y_i$, за упреждающее планирование технического обслуживания. Если $y_i > y_i$, то применяется больший штраф из-за более серьезных последствий, когда техническое обслуживание выполняется слишком поздно.

$$Score = \begin{cases} \sum_{i=1}^N e^{-\left(\frac{y_i - y_i}{13}\right)} - 1, & y_i - y_i < 0, \\ \sum_{i=1}^N e^{-\left(\frac{y_i - y_i}{10}\right)} - 1, & y_i - y_i \geq 0. \end{cases}$$

Здесь y_i – прогнозируемый RUL; y_i – истинный RUL; N – количество последовательностей выборок в наборе данных.

Для сравнения и оценки моделей используется общедоступный набор данных турбовентиляторных двигателей C-MAPSS, содержащий четыре подгруппы данных: FD001, FD002, FD003, FD004. Данные в каждой подгруппе предназначены для оценки производительности модели в различных условиях. Эксплуатационные условия и режимы неисправностей создают дополнительную сложность набора данных, делая его подходящим эталоном для оценки эффективности предиктивных моделей.

Сравнение моделей прогнозирования оставшегося срока полезного использования авиационных двигателей

Метод	Значения метрик для разных подгрупп данных							
	FD001		FD002		FD003		FD004	
	RMSE	Score	RMSE	Score	RMSE	Score	RMSE	Score
CNN (2016)	18,45	1290	30,29	13600	19,82	1600	29,16	7890
LSTM (2017)	16,14	338	24,49	4450	16,18	852	28,17	5550
BiLSTM (2018)	13,65	295	23,18	4130	13,74	317	24,86	5430
Multi-head CNN+LSTM (2020)	12,19	259	19,93	4350	12,85	343	22,89	4340
GCT (2021)	11,27	–	22,81	–	11,42	–	24,86	–
B-LSTM (2022)	12,45	279	15,36	4250	13,37	356	16,24	5220
DAST (2022)	11,43	203	15,25	924,96	11,32	154	18,36	1490
BiLSTM-DAE Transformer (2023)	10,98	186	16,12	2937	11,14	252	18,15	3840
STAR (2024)	10,61	169	13,47	784	10,71	202	15,87	1449

2. ПЛАНИРОВАНИЕ ТЕХНИЧЕСКОГО ОБСЛУЖИВАНИЯ АВИАЦИОННЫХ ДВИГАТЕЛЕЙ

В § 1 рассмотрены методы прогнозирования оставшегося срока полезного использования авиационных двигателей. Возникает задача интеграции такого прогноза в планирование технического обслуживания, которая рассматривается в нескольких исследованиях.

Метод обучения с подкреплением широко применяется для решения различных задач, в том числе для оптимального прогнозирования технического обслуживания в различных формах – от ранней диагностики до прямого предложения действий по техническому обслуживанию [69]. Подход на основе обучения с подкреплением был предложен в работе [70] для решения задачи оптимизации долгосрочного обслуживания самолета. Предлагаемый метод использует информацию о будущем полете самолета, стоимости ремонта, прогнозах, управлении состоянием и т. д. для принятия решений по последовательному техническому обслуживанию в режиме реального времени. Интеграция модели обучения с подкреплением для сотрудничества человека и искусственного интеллекта при планировании технического обслуживания и визуализация индикаторов технического обслуживания по состоянию были предложены в статье [71]. В публикации [72] предлагается применять обучение с подкреплением для планирования задач по техническому обслуживанию. Подход состоит из статического алгоритма для долгосрочного планирования и адаптивного алгоритма для перепланирования на основе оптимального принятия решений по техническому обслуживанию в случае непредвиденных событий. В исследовании [73] представлен метод прогнозирования внеплановых действий по техническому обслуживанию самолетов путем применения методов глубокого обучения с подкреплением и данных из журналов центральной системы технического обслуживания самолетов.

В работе [74] предложена система динамического технического обслуживания парка самолетов, в которой прогнозы оставшегося срока полезного использования компонентов периодически обновляются. Планирование задач по техническому обслуживанию инициируется, как только срабатывает сигнал тревоги. Сигналы тревоги основаны на изменении прогнозов с течением времени. Задачи планируются с применением подхода «скользящий горизонт» с временными окнами. В каждом временном окне интервалы времени, в которых запланировано техническое обслуживание, определяются при помощи целочисленного линей-

ного программирования. Параметры структуры обслуживания получаются с помощью генетического алгоритма.

Предлагаемая структура технического обслуживания иллюстрируется на примере парка из 20 самолетов из набора данных C-MAPSS; каждый из самолетов оснащен двумя турбовентиляторными двигателями. Прогнозы оставшегося срока полезного использования турбовентиляторных двигателей получаются с использованием сверточной нейронной сети и обновляются каждый день. Результаты показывают, что вследствие несовершенного прогнозирования отказы двигателей по-прежнему происходят из-за ограниченного количества мест для обслуживания или из-за ограниченного количества задач по техническому обслуживанию, которые можно выполнить за ограниченное время. По сравнению со случаем идеального прогнозирования затраты на техническое обслуживание выше на 24,4 %.

В прогнозировании большое значение имеет учет неопределенности, присущей моделям и данным. В результате, чтобы прогноз оставшегося срока полезного использования имел смысл, он должен по крайней мере сопровождаться доверительными интервалами и, что еще лучше, описанием через распределения вероятностей, если это возможно, или нечеткими представлениями [75].

В работе [76] предлагается подход к интеграции распределения вероятностей оставшегося срока полезного использования авиационных двигателей в оптимальное планирование замены двигателей. Вероятностные прогнозы рассчитываются на основе сверточных нейронных сетей и метода исключения Монте-Карло [77]. 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 потерянный срок использования двигателей [76].

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 срок полезного использования двигателя меньше или равен k циклам при x_t :

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

Двигатель выходит из строя на k -м цикле, если $k-1 < \rho_t \leq k$, где ρ_t – истинный оставшийся срок полезного использования двигателя; R_t – оценка



ρ_t – прогнозируемый оставшийся срок полезного использования 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:

$$a_t = \begin{cases} k, & 0 < k \leq D - \text{заменить двигатель в цикле } k, \\ K, & K > D - \text{не заменять двигатель.} \end{cases}$$

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 значений a_t и ρ_t :

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

где $c_{\text{sch}}(k) = c_0 - c_1 k$ – стоимость плановой замены двигателя в цикле k ; $c_0 > 0$ – фиксированная стоимость замены; $c_1 > 0$ – штраф за досрочную замену; $c_{\text{uns}} > c_0$ – 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» [78]. 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 срока полезного ис-

пользования. Такой подход позволит снизить затраты на техническое обслуживание и уменьшить количество внеплановых мероприятий по сравнению с другими стратегиями технического обслуживания.

ЗАКЛЮЧЕНИЕ

Переход к прогнозному техническому обслуживанию, основанному на данных бортовых датчиков мониторинга состояния авиационных двигателей и оценке их оставшегося срока полезного использования, позволит повысить безопасность эксплуатации и сократить затраты на техническое обслуживание самолетов. На основе проведенного обзора литературы можно сделать вывод, что, учитывая характер временных рядов данных мониторинга авиационного двигателя, тенденция применения подходов к оценке оставшегося срока полезного использования и прогнозирования отказов авиационного двигателя смещается от традиционных методов машинного обучения в сторону глубокого обучения нейронных сетей. 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, а также архитектуры трансформера на основе механизма внимания. В последние годы появились попытки обеспечить интерпретируемость при сохранении точности прогнозирования на основе моделей, таких как SHAP (*SHapely Additive exPlanations*) и LIME.

Необходимо отметить, что для анализа и сравнения эффективности предлагаемых методов и алгоритмов авторы в большинстве случаев используют общедоступный набор данных моделирования работы до отказа турбовентиляторных двигателей C-MAPSS. Однако существуют значительные различия между данными моделирования и данными, получаемыми в условиях практических полетов. Необходимы дальнейшие исследования для прогнозирования оставшегося срока службы на основе реальных наборов данных о состоянии авиационных двигателей.

Цель прогнозирования оставшегося срока полезного использования авиационных двигателей – предвидеть сбой и оптимизировать выполнение задач по техническому обслуживанию. 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.

ЛИТЕРАТУРА

1. *Fentaye, D., Zaccaria, V., Kyprianidis, K.* Aircraft Engine Performance Monitoring and Diagnostics Based on Deep Convolutional Neural Networks // *Machines*. – 2021. – Vol. 9, no. 12. – Art. no. 337. – DOI: 10.3390/machines9120337
2. *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. 72. – P. 1–15. – DOI: 10.1109/TIM.2023.3236342
3. *Upadhyay, R., Amhia, H.* LSTM-Based Approach for Remaining Useful Life Prediction of Air Craft Engines // *ITM Web of Conferences*. – 2023. – Vol. 57. – Art. no. 03004. – DOI: 10.1051/itmconf/20235703004
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, iss. 2. – P. 216–237. – DOI: 10.1002/sys.21651
5. *Кулида Е.Л., Лебедев В.Г.* Прогнозирование технического обслуживания авиационных двигателей на основе глубокого обучения // *Материалы XIV Всероссийского совещания по проблемам управления (ВСПУ-2024)*. – Москва, 2024. – С. 2502–2506. [*Kulida, E.L., Lebedev, V.G.* Prognozirovanie tekhnicheskogo obsluzhivaniya aviatsionnykh dvigatelei na osnove glubokogo obucheniya // *Materialy XIV Vserossiiskogo soveshchaniya po problemam upravleniya (VSPU-2024)*. – Moscow, 2024. – S. 2502–2506. (In Russian)]
6. *Сай В.К., Щербakov М.В.* Прогнозирование отказов сложных многообъектных систем на основе комбинации нейросетей: пути повышения точности прогнозирования // *Прикаспийский журнал: управление и высокие технологии*. – 2020 – № 1 (49). – С. 49–60. – DOI: 10.21672/2074–1707.2020.49.4.049–060 [*Sai, V.K., Shcherbakov, M.V.* Prognozirovanie otkazov slozhnykh mnogoob"ektnykh sistem na osnove kombinatsii neirosetei: puti povysheniya tochnosti prognozirovaniya // *Prikaspiiskii zhurnal: upravlenie i vysokie tekhnologii*. – 2020 – № 1 (49). – P. 49–60. – DOI: 10.21672/2074–1707.2020.49.4.049–060 (In Russian)]
7. *Scott, M.J., Verhagen, W.J.C., Bieber, M.T., Marzocca, P.* A Systematic Literature Review of Predictive Maintenance for Defence Fixed-Wing Aircraft Sustainment and Operations // *Sensors*. – 2022. – Vol. 22, no. 18. – Art. no. 7070. – DOI: 10.3390/s22187070
8. *Khalid, S., Song, J., Azad, M.M.* A Comprehensive Review of Emerging Trends in Aircraft Structural Prognostics and Health Management // *Mathematics*. – 2023. – Vol. 11, no. 18. – Art. no. 3837. – DOI: 10.3390/math11183837
9. *Naderi, E., Meskin N., Khorasani, K.* Nonlinear Fault Diagnosis of Jet Engines by Using a Multiple Model-based Approach // *J. Eng. Gas Turbines Power*. – 2012. – Vol. 13, no. 1. – DOI: 10.1115/GT2010-23442
10. *Amirkhani, S., Tootchi, A., Chaibakhsh, A.* Fault Detection and Isolation of Gas Turbine Using Series-parallel NARX Model // *ISA Transactions*. – 2022. – Vol. 120. – P. 205–221. – DOI: 10.1016/j.isatra.2021.03.019
11. *Gharoun, H., Keramati, A., Nasiri, M., Azadeh, A.* An Integrated Approach for Aircraft Turbofan Engine Fault Detection Based on Data Mining Techniques // *Expert system*. – 2021. – Vol. 36, no. 4. – DOI: 10.1111/essy.12370
12. *Gharoun, H., Hamid, M., Ghaderi, S.F., Nasiri, M.* Anomaly Detection via Data Techniques for Aircraft Engine Operation Monitoring // *Proceedings of 4th International Industrial Engineering Conference (IEEC 2018)*. – Tehran, Iran, 2018. – P. 1–15.
13. *Garcia, C.E., Camana, M.R., Koo, I.* Machine Learning-based Scheme for Multi-class Fault Detection in Turbine Engine Disks // *ICT Express*. – 2021. – Vol. 7, iss. 1. – P. 15–22. – DOI: 10.1016/j.ict.2021.01.009
14. *Li, Z, Goebel, K., Wu, D.* Degradation Modeling and Remaining Useful Life Prediction of Aircraft Engines Using Ensemble Learning // *Journal of Engineering for Gas Turbines and Power*. – 2018. – Vol. 141, no. 4. – DOI: 10.1115/1.4041674
15. *Celikmih, K., Inan, O., Uguz, H., et al.* Failure Prediction of Aircraft Equipment Using Machine Learning with a Hybrid Data Preparation Method // *Scientific Programming*. – 2020. – Vol. 10. – DOI: 10.1155/2020/8616039.
16. *Costa, N., Sánchez, L.* Variational Encoding Approach for Interpretable Assessment of Remaining Useful Life Estimation // *Reliability Engineering and System Safety*. – 2022. – Vol. 222, no. 1. – DOI: 10.1016/j.res.2022.108353
17. *Abdullah, T.A.A., Zahid, M.S.M., Turki, A.F., et al.* Sig-LIME: a Signal-Based Enhancement of LIME Explanation Technique // *IEEE Access*. – 2024. – Vol. 12. – P. 52641–52658. – DOI: 10.1109/ACCESS.2024.3384277
18. *Gao, J., Wang, Y., Sun, Z.* An Interpretable RUL Prediction Method of Aircraft Engines Under Complex Operating Conditions Using Spatio-temporal Features // *Measurement Science and Technology*. – 2024. – Vol. 35, no. 7. – DOI: 10.1088/1361–6501/ad3b2c
19. *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. – DOI: 10.1016/j.res.2021.107961
20. *Adhikari, P., Rao, H.G., Buderath, M.* Machine Learning Based Data Driven Diagnostics & Prognostics Framework for Aircraft Predictive Maintenance // *Proceedings of the 10th International Symposium on NDT in Aerospace*. – Dresden, Germany, 2018. – P. 24–26.
21. *Graves, A., Schmidhuber, J.* Framewise Phoneme Classification with Bidirectional LSTM and Other Neural Network Architectures // *Neural Networks*. – 2005. – Vol. 18, no. 5–6. – P. 602–610. – DOI: 10.1016/j.neunet.2005.06.042
22. *Graves, A., Jaitly, N., Mohamed, A.R.* Hybrid Speech Recognition with Deep Bidirectional LSTM // *Proceedings of 2013 IEEE Workshop on Automatic Speech Recognition and Understanding*. – Olomouc, Czech Republic, 2014. – P. 273–278. – DOI: 10.1109/ASRU.2013.6707742
23. *Kefalas, M., Baratchi, M., Apostolidis, A., et al.* Automated Machine Learning for Remaining Useful Life Estimation of Aircraft Engines // *Proceedings of the IEEE International*



- Conference on Prognostics and Health Management (ICPHM). – Detroit, USA, 2021. – DOI: 10.1109/ICPHM51084.2021.9486549
24. *Liu, L., Song, X., Zhou, Z.* Aircraft Engine Remaining Useful Life Estimation Via a Double Attention-based Data-driven // Reliability Engineering and System Safety. – 2022. – Vol. 221, no. 3. – DOI: 10.1016/j.ress.2022.108330
25. *Сай В.К.* Глубокие нейронные сети для предсказательного технического обслуживания // Моделирование, оптимизация и информационные технологии. – 2019. – Т. 7, № 4. – DOI: 10.26102/2310-6018/2019.27.4.011 [*Cai, V.K.* Glubokie neironnye seti dlya predskazatel'nogo tekhnicheskogo obsluzhivaniya // Modelirovanie, optimizatsiya i informatsionnye tekhnologii. – 2019. – Т. 7, no. 4. – DOI: 10.26102/2310-6018/2019.27.4.011 (In Russian)]
26. *Xia, J., Feng, Y., Lu, C., et al.* LSTM-Based Multi-layer Self-attention Method for Remaining Useful Life Estimation of Mechanical Systems // Engineering Failure Analysis. – 2021. – Vol. 125, no. 12. – DOI: 10.1016/j.engfail.2021.105385
27. *Dangut, M.D., Skaf, Z., Jennions, I.K.* Rare Failure Prediction Using an Integrated Auto-encoder and Bidirectional Gated Recurrent Unit Network // IFAC-PapersOnLine. – 2020. – Vol. 53, iss. 4. – P. 276–282.
28. *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
29. *Сыпало, К.И., Пономарев, А.К., Ахатов, И.Ш.* Перспективные технологии для авиационной промышленности: Аналитический обзор. – М.: НАУКА, 2017. – 463 с. [*Sypalo, K.I., Ponomarev, A.K., Akhatov, I.Sh.* Perspektivnye tekhnologii dlya aviatsionnoi promyshlennosti: analiticheskii obzor. – Moscow: Nauka, 2017. – 463 s. (In Russian)]
30. *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
31. *Zhao, Y., Wang, Y.* Remaining Useful Life Prediction for Multi-sensor Systems Using a Novel End-to-End Deep-learning Method // Measurement. – 2021. – Vol. 182, no. 163. – DOI: 10.1016/j.measurement.2021.109685
32. *Frederick, D.K., DeCastro, J.A., Litt, J.S.* User's Guide for the Commercial Modular Aero-propulsion System Simulation (C-MAPSS). Report no. NASA/TM-2007-215026. – Cleveland: National Aeronautics and Space Administration, 2007. – 47 p.
33. *Saxena, A., Goebel, K., Simon, D., Eklund, N.* Damage Propagation Modeling for Aircraft Engine Run-to-Failure Simulation // Proceedings of International Conference on Prognostics and Health Management. – Denver, USA, 2008. – DOI: 10.1109/PHM.2008.4711414
34. *Song, Y., Bliet, 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 (ESREL 2021). – P. 603–609. – DOI: 10.3850/978-981-18-2016-8_478-cd
35. *Chao, M.A., Kulkarni, C., Goebel, K., Fink, O.* Aircraft Engine Run-to-Failure Dataset under Real Flight Conditions for Prognostics and Diagnostics // Data. – 2021. – Vol. 6 (1), no. 5. – DOI: 10.3390/data6010005
36. *Azyus, A.F.* Determining the Method of Predictive Maintenance for Aircraft Engine Using Machine Learning // Journal of Computer Science and Technology Studies. – 2022. – Vol. 4, no. 1. – DOI: 10.32996/jcsts.2022.4.1.1
37. *Hasib, A.A., Rahman, A., Khabir, M., Shawon, M.T.R.* An Interpretable Systematic Review of Machine Learning Models for Predictive Maintenance of Aircraft Engine // arXiv. – 2023. – arXiv:2309.13310v1. – DOI: <https://doi.org/10.48550/arXiv.2309.13310>
38. *Liu, T., Bao, J., Wang, J., Wang, J.* Deep Learning for Industrial Image: Challenges, Methods for Enriching the Sample Space and Restricting the Hypothesis Space, and Possible Issue // International Journal of Computer Integrated Manufacturing. – 2022. – Vol. 35, iss. 10–11. – P. 1077–1106. – DOI: 10.1080/0951192X.2021.1901319
39. *Hinton, G.E., Salakhutdinov, R.R.* Reducing the Dimensionality of Data with Neural Networks // Science. – 2006. – Vol. 313. – P. 504–507. – DOI: 10.1126/science.1127647
40. *Fu, S., Zhong, S., Lin, L., Zhao, M.* A Re-optimized Deep Auto-encoder for Gas Turbine Unsupervised Anomaly Detection // Engineering Applications of Artificial Intelligence. – 2021. – Vol. 101, no. 12. – DOI: 10.1016/j.engappi.2021.104199
41. *Babu, G.S., Zhao, P., Li, X.* Deep Convolutional Neural Network Based Regression Approach for Estimation of Remaining Useful Life // Proceedings of the International Conference on Database Systems for Advanced Applications (DASFAA). – Dallas, USA, 2016. – Vol. 9642. – P. 214–228. – DOI: 10.1007/978-3-319-32025-0_14
42. *Li, X., Ding, Q., Sun, J.Q.* Remaining Useful Life Estimation in Prognostics Using Deep Convolution Neural Networks // Reliability Engineering and System Safety. – 2018. – Vol. 172, no. 1–2. – DOI: 10.1016/j.ress.2017.11.021
43. *Li, H., Zhao, W., Zhang, Y., Zio, E.* Remaining Useful Life Prediction Using Multiscale Deep Convolutional Neural Network // Applied Soft Computing. – 2020. – Vol. 89. – DOI: 10.1016/j.asoc.2020.106113
44. *Абдуракунов С.С., Бутаков Е.Б.* Сравнительный анализ алгоритмов машинного обучения для определения предотказных и аварийных состояний авиадвигателей // Автометрия. – 2020. – Т. 56, № 6. – С. 34–48. – DOI: 10.15372/AUT20200605 [*Abdurakipov, S.S., Butakov, E.B.* Sravnitel'nyi analiz algoritmov mashinnogo obucheniya dlya opredeleniya predotkaznykh i avariinykh sostoyanii aviadvigateli // Avtometriya. – 2020. – Т. 56, no. 6. – S. 34–48. (In Russian)]
45. *Schuster, M., Paliwal, K.K.* Bidirectional Recurrent Neural Networks // IEEE Transactions on Signal Processing. – 1997. – Vol. 45, no. 11. – P. 2673–2681. – DOI: 10.1109/78.650093
46. *Hu, K., Cheng, Y., Wu, J., et al.* Deep Bidirectional Recurrent Neural Networks Ensemble for Remaining Useful Life Prediction of Aircraft Engine // IEEE Transactions on Cybernetics. – 2021. – Vol. 53, no. 4. – P. 2531–2543. – DOI: 10.1109/TCYB.2021.3124838
47. *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
48. *Wang, J., Wen, G., Yang, S., Liu, Y.* Remaining Useful Life Estimation in Prognostics Using Deep Bidirectional LSTM Neural Network // Proceedings of the 2018 Prognostics and System Health Management Conference (PHM-Chongqing). – Chongqing, China, 2018. – P. 1037–1042. – DOI: 10.1109/PHM-Chongqing.2018.00184
49. *Khan, K., Sohaib, M., Rashid, A., et al.* Recent Trends and Challenges in Predictive Maintenance of Aircraft's Engine and

- Hydraulic System // Journal of the Brazilian Society of Mechanical Sciences and Engineering. – 2021. – Vol. 43. – P. 1–17. – DOI: 10.1007/s40430-021-03121-2
50. Wu, Q., Ding, K., Huang, B. Approach for Fault Prognosis Using Recurrent Neural Network // Journal of Intelligent Manufacturing. – 2020. – Vol. 31, no. 3. – P. 1621–1633. – DOI: 10.1007/s10845-018-1428-5
51. Peng, C., Chen, Y., Chen, Q., et al. A Remaining Useful Life Prognosis of Turbofan Engine Using Temporal and Spatial Feature Fusion // Sensors. – 2021. – Vol. 21, no. 2. – DOI: 10.3390/s21020418
52. da Rosa, T.G., de Melani, A.H.A., Pereira, F.H., et al. Semi-Supervised Framework with Autoencoder-Based Neural Networks for Fault Prognosis // Sensors. – 2022. – Vol. 22, no. 24. – DOI: 10.3390/s22249738
53. Peng, C., Wu, J., Wang, Q. Remaining Useful Life Prediction Using Dual-Channel LSTM with Time Feature and Its Difference // Entropy. – 2022. – Vol. 24, no. 12. – DOI: 10.3390/e24121818
54. Wang, X., Huang, T., Zhu, K., Zhao, X. LSTM-Based Broad Learning System for Remaining Useful Life Prediction // Mathematics. – 2022. – Vol. 10, no. 12. – DOI: 10.3390/math10122066
55. Azyus, A.F., Wijaya, S.K., Naved, M. Determining RUL Predictive Maintenance on Aircraft Engines Using GRU // Journal of Mechanical, Civil and Industrial Engineering. – 2022. – Vol. 3, no. 3. – P. 79–84. – DOI: 10.32996/jmci.2022.3.3.10
56. Boujamza, A., Elhaq, S.L. Attention-Based LSTM for Remaining Useful Life Estimation of Aircraft Engines // Advances in Control and Optimization of Dynamical Systems. – 2022. – Vol. 55, iss. 12. – P. 450–455. – DOI: 10.1016/j.ifacol.2022.07.353
57. Jiang, Y., Li, C., Yang, Z., et al. Remaining Useful Life Estimation Combining Two-step Maximal Information Coefficient and Temporal Convolutional Network with Attention Mechanism // IEEE Access. – 2021. – Vol. 9. – P. 16 323–16 336. – DOI: 10.1109/ACCESS.2021.3052305
58. Xia, J., Feng, Y., Teng, D., et al. Distance Self-attention Network Method for Remaining Useful Life Estimation of Aeroengine with Parallel Computing // Reliability Engineering and System Safety. – 2022. – Vol. 225, no. 1. – DOI: 10.1016/j.res.2022.108636
59. Vaswani, A., Shazeer, N., Parmar, N., et al. Attention Is All You Need // Proceedings of 31st Conference on Neural Information Processing Systems (NIPS 2017). – Long Beach, CA, USA, 2017. – P. 5998–6008. – DOI: 10.48550/arXiv.1706.03762
60. Ma, Q., Zhang, M., Xu, Y., et al. Remaining Useful Life Estimation for Turbofan Engine with Transformer-based Deep Architecture // Proceedings of the 26th International Conference on Automation and Computing (ICAC). – Portsmouth, United Kingdom, 2021. – DOI: 10.23919/ICAC50006.2021.9594150
61. Zhang, Z., Song, W., Li, Q. Dual-Aspect Self-Attention Based on Transformer for Remaining Useful Life Prediction // IEEE Transactions on Instrumentation and Measurement. – 2022. – Vol. 71. – DOI: 10.1109/TIM.2022.3160561
62. Chadha, G.S., Shah, S.R.B., Schwung, A., Ding, S.X. Shared Temporal Attention Transformer for Remaining Useful Lifetime Estimation // IEEE Access. – 2022. – Vol. 10. – DOI: 10.1109/ACCESS.2022.3187702
63. Fan, Z., Li, W., Chang, K.-C. A Two-Stage Attention-Based Hierarchical Transformer for Turbofan Engine Remaining Useful Life Prediction // Sensors. – 2024. – Vol. 24, no. 3. – DOI: 10.3390/s24030824
64. Xiang, F., Zhang, Y., Zhang, S., et al. Bayesian Gated-Transformer Model for Risk-Aware Prediction of Aero-Engine Remaining Useful Life // Expert System with Applications. – 2024. – Vol. 238, no. 1. – DOI: 10.1016/j.eswa.2023.121859
65. Fan, Z., Li, W., Chang, K.-C. A Bidirectional Long Short-Term Memory Autoencoder Transformer for Remaining Useful Life Estimation // Mathematics. – 2023. – Vol. 11, iss. 24. – DOI: 10.3390/math11244972
66. Zheng, S., Ristovski, K., Farahat, A., Gupta, C. Long Short-Term Memory Network for Remaining Useful Life Estimation // Proceedings of the 2017 IEEE International Conference on Prognostics and Health Management (ICPHM). – Dallas, TX, USA, 2017. – P. 88–95. – DOI: 10.1109/ICPHM.2017.7998311
67. Mo, H., Lucca, F., Malacarne, J., Iacca, G. Multi-Head CNN-LSTM with Prediction Error Analysis for Remaining Useful Life Prediction // Proceedings of the 27th Conference of Open Innovations Association (FRUCT). – Trento, Italy, 2020. – P. 164–171. – DOI: 10.23919/FRUCT49677.2020.9111058
68. Mo, Y., Wu, Q., Li, X., Huang, B. Remaining Useful Life Estimation via Transformer Encoder Enhanced by a Gated Convolutional Unit // Journal of Intelligent Manufacturing. – 2021. – Vol. 32. – P. 1997–2006. – DOI: 10.1007/s10845-021-01750-x
69. Siraskar, R., Kumar, S., Patil, S., et al. Reinforcement Learning for Predictive Maintenance: A Systematic Technical Review // Artificial Intelligence Review. – 2023. – Vol. 56. – P. 12 885–12 947. – DOI: 10.1007/s10462-023-10468-6
70. Hu, Y., Miao, X., Zhang, J., et al. Reinforcement Learning Driven Maintenance Strategy: A Novel Solution for Long-term Aircraft Maintenance Decision Optimization // Computers & Industrial Engineering. – 2021. – Vol. 153. – DOI: 10.1006/j.cie.2020.107056
71. Ribeiro, J., Andrade, P., Carvalho, M., et al. Playful Probes for Design Interaction with Machine Learning: A Tool for Aircraft Condition-based Maintenance Planning and Visualisation // Mathematics. – 2022. – Vol. 10, no. 9. – DOI: 10.3390/math.10091604
72. Silva, C., Andrade, P., Ribeiro, B., Santos, B.F. Adaptive Reinforcement Learning for Task Scheduling in Aircraft Maintenance // Scientific Reports. – 2023. – Vol. 13 (1). – DOI: 10.1038/s41598-023-41169-3
73. Dangut, M.D., Jennions, I.K., King, S., Skaf, Z. Application of Deep Reinforcement Learning for Extremely Rare Failure Prediction in Aircraft Maintenance // Mechanical Systems and Signal Processing. – 2022. – Vol. 171, no. 8. – DOI: 10.1016/j.ymsp.2022.108873
74. Pater, I., Reijns, A., Mitici, M. Alarm-based Predictive Maintenance Scheduling for Aircraft Engines with Imperfect Remaining Useful Life Prognostics // Reliability Engineering and System Safety. – 2022. – Vol. 221. – DOI: 10.1016/j.res.2022.108341
75. Fink, O., Wang, Q., Svensén, M., et al. Potential, Challenges and Future Directions for Deep Learning in Prognostics and Health Management Applications // Engineering Applications and Artificial Intelligence. – 2020. – Vol. 92, no. 033. – DOI: 10.1016/j.engappai.2020.103678
76. 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, no. 1. – DOI: 10.1016/j.res.2022.108908
77. Srivastava, N., Hinton, G., Sutskever, A., et al. A Simple Way to Prevent Neural Networks from Overfitting // Journal of



Machine Learning Research. – 2014. – Vol. 15. – DOI: 10.5555/2627435.2670313

78. Naarsoja, T., Zhou, A., Abbeel, P., Levine, S. Soft Actor-critic: Off-policy Maximum Entropy Deep Reinforcement Learning with a Stochastic Actor // Proceedings of the 35th International Conference on Machine Learning (ICML). – Stockholm, Sweden, 2018. – Vol. 5. – P. 2976–2989.

Статья представлена к публикации членом редколлегии
Ф.Ф. Пащенко.

Поступила в редакцию 05.09.2024,
после доработки 10.10.2024.
Принята к публикации 05.12.2024.

Кулида Елена Львовна – канд. техн. наук,
✉ elena-kulida@yandex.ru
ORCID iD: <https://orcid.org/0009-0003-0226-9708>

Лебедев Валентин Григорьевич – д-р техн. наук,
✉ lebedev-valentin@yandex.ru
ORCID iD: <https://orcid.org/0000-0003-3206-9558>

Институт проблем управления им. В. А. Трапезникова РАН,
г. Москва

© 2024 г. Кулида Е. Л., Лебедев В. Г.



Эта статья доступна по [лицензии Creative Commons «Attribution» \(«Атрибуция»\) 4.0 Всемирная](https://creativecommons.org/licenses/by/4.0/).

PROSPECTIVE APPROACHES TO PREDICTING THE REMAINING USEFUL LIFE OF AIRCRAFT ENGINES

E.L. Kulida* and V.G. Lebedev**

Trapeznikov Institute of Control Sciences, Russian Academy of Sciences, Moscow, Russia

*✉ elena-kulida@yandex.ru, **✉ lebedev-valentin@yandex.ru

Abstract. This survey covers the literature on the fault diagnosis and prediction of the remaining useful life of aircraft engines based on deep learning. A formal statement of the remaining useful life estimation problem is given. The basic architectures of deep neural networks are considered to detect rare failures and predict the next failures using aircraft engine condition monitoring data. The extraction of informative features using autoencoders is discussed. The structure of long short-term memory (LSTM) and attention mechanism (AM) cells applied in deep neural networks to predict the remaining useful life is described. The problem of integrating remaining useful life prediction into maintenance planning based on reinforcement learning is considered.

Keywords: aircraft engine diagnosis, predictive maintenance, remaining useful life prediction, deep learning.

Acknowledgments. This work was supported in part by the Russian Science Foundation, project no. 23-19-00464.