УДК 629.7

DOI: http://doi.org/10.25728/pu.2024.3.1

СОВРЕМЕННЫЕ ПОДХОДЫ К ДИАГНОСТИКЕ И ПРОГНОЗИРОВАНИЮ ТЕХНИЧЕСКОГО СОСТОЯНИЯ ЭЛЕКТРОМЕХАНИЧЕСКОГО ПРИВОДА ЛЕТАТЕЛЬНОГО АППАРАТА[#]

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. В связи с реализацией концепции электрических самолетов отмечена необходимость обеспечения высокой надежности электромеханических приводов, являющихся важными компонентами авиационных систем. Рассмотрен структурный состав электромеханического привода и виды его неисправностей. Приведен обзор методов диагностики неисправностей электромеханического привода, основанных либо на моделировании электромеханического привода, либо на анализе сигналов, поступающих в процессе функционирования электромеханического привода, а также гибридных методов, сочетающих в себе оба этих подхода. Исследованы преимущества, недостатки и трудности в применении различных подходов. Особое внимание уделено методам диагностики электромеханических приводов на основе глубокого обучения, которые позволяют в автоматическом режиме обрабатывать сигналы и реализовать комплексную диагностику неисправностей. Представлена концепция технического обслуживания авиационной техники, в частности электромеханических приводов, на основе оценки технического состояния и прогнозирования оставшегося срока полезного использования с целью предупреждения неисправностей до их появления. Для решения проблемы технического обслуживания летательных аппаратов на основе прогнозирования выделен ряд гибридных подходов. Приведен обзор отечественных разработок в области авиационной диагностики с применением машинного обучения.

Ключевые слова: летательный аппарат, электромеханический привод, метод диагностики неисправностей, оценка технического состояния.

ВВЕДЕНИЕ

Концепция электрических самолетов, среди прочих улучшений, требует постепенной замены гидравлических приводов электромеханическими приводами летательных аппаратов (ЭПЛА), которые смогут обеспечить значительные преимущества по сравнению с гидравлическими приводами при управлении полетом [1, 2]. Считается, что такая замена приведет к значительному снижению веса, значительной экономии стоимости жизненного цикла, меньшему воздействию на окружающую среду и повышению надежности летательного аппарата (ЛА). Использование ЭПЛА становится все более распространенным, но их широкое применение замедляется из-за ограниченного опыта с точки зрения безопасности и надежности и в настоящее время в основном ограничивается системами, некритичными для безопасности. Важно оценить последствия замены гидравлической подсистемы ее электрической альтернативой с точки зрения использования, реализации, мониторинга, а также надежности и безопасности оборудования. Возникают проблемы, которые менее важны для гидравлических приводов, такие как электромагнитная совместимость, механическое заклинивание и проблемы с перегревом из-за высоких токов [3]. Для поддержки использования ЭПЛА необхо-

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

димы надежные прогностические инструменты, обеспечивающие точную оценку их фактического состояния и оставшегося срока полезного использования. Общий обзор ЭПЛА, а также связанных с ними возможностей и проблем приводится в работах [4, 5].

Приводы являются важными с точки зрения безопасности компонентами авиационных систем, и необнаруженная неисправность привода может привести к серьезным последствиям, поэтому для повышения производительности ЭПЛА, надежности, безопасности и снижения затрат необходимо применение технологии технического обслуживания по состоянию.

Фундаментальным инструментом раннего выявления неисправностей ЭПЛА становятся инновационные методологии прогнозирования и диагностики, в основе которых лежит численное моделирование. Системы прогнозирования и управления работоспособностью (англ. *Prognostics and Health Management,* PHM) – это относительно новая область исследований для диагностики текущего технического состояния и прогнозирования времени отказа и оставшегося срока полезного использования системы или компонента на основе поступающих от них сигналов [6]. Такие системы позволяют запланировать техническое обслуживание для обеспечения безотказного функционирования системы на основе набора численных моделей, которые должны быть правильно настроены для воспроизведения поведения ЭПЛА с точки зрения статической и динамической реакции (например, токов, напряжений, скорости, положения и т. д.) [7, 8]. С этой целью должно быть обеспечено моделирование работы ЭПЛА в нормальных условиях, а также при наличии зарождающихся неисправностей. Результаты, тенденции, значения и прогнозы модели в целом должны быть тщательно проверены на основе подробных и обширных наборов экспериментальных данных. Широко распространенным методом, применяемым в тех инженерных приложениях, которые включают разработку новых моделей для мониторинга и управления, является экспериментальная проверка моделей на испытательных стендах [9].

При диагностике неисправностей ЭПЛА применяются методы обработки сигналов и статистические инструменты с различными типами датчиков, быстрое преобразование Фурье, частотный анализ вибраций, частотно-временной анализ [10–13]. Однако применение этих методов может занять много времени, быть трудоемким и ненадежным. В последние годы развивается новый подход к автоматизации диагностики и прогнозированию неисправностей на основе методов глубокого обучения для классификации различных состояний ЭПЛА с использованием различных видов нейронных сетей, таких как автоэнкодер с шумоподавлением, сеть глубокого доверия, сверточные нейронные сети. В отличие от традиционных методов, с помощью методов глубокого обучения можно извлекать эффективные признаки неисправностей прямо из сигналов мониторинга и одновременно выполнять классификацию неисправностей [14, 15].

Целью работы является исследование и анализ современных подходов к диагностике и прогнозированию технического состояния электромеханического привода летательного аппарата, их перспективности и трудностей, препятствующих в настоящее время их практическому применению.

1. СТРУКТУРНЫЙ СОСТАВ ЭЛЕКТРОМЕХАНИЧЕСКОГО ПРИВОДА И ВИДЫ ЕГО НЕИСПРАВНОСТЕЙ

Большинство ЭПЛА состоит из серводвигателя, электрической цепи силового привода, механических компонентов, блока управления приводом и некоторых типов датчиков [16, 17]. Электрический силовой привод получает сигнал от блока управления приводом и выдает соответствующий силовой ток для привода серводвигателя. Серводвигатель преобразует электрическую энергию в механическую и приводит в действие исполнительные устройства, которые в зависимости от кинематики их движения подразделяют на механизмы поступательного, поворотного и вращательного движения. При реализации управления с обратной связью в ЭПЛА обычно устанавливаются датчики обратной связи, а для контроля состояния привода – датчики мониторинга.

В ЭПЛА выделяются следующие виды неисправностей: неисправность двигателя, неисправность электрического силового привода, неисправность механических компонентов [18].

Неисправности двигателя в основном включают неисправность подшипников, неисправность обмотки статора и неисправность ротора. К неисправностям подшипников относятся износ, точечная коррозия и разрушение сепаратора. Неисправности подшипников могут привести к дисбалансу трения и ненормальной вибрации, что снизит эффективность и производительность двигателя. Неисправности обмотки статора включают обрыв обмотки, короткое замыкание и т. д. Обрыв обмотки обычно вызван большими пусковыми токами двигателя и приводит к резкому снижению выходного момента ЭПЛА и к резкому увеличению то-

ков обмотки. Короткое замыкание в основном вызывается длительным тепловым старением и приводит к увеличению тока обмотки и к выделению двигателем большого количества тепла. Неисправности ротора двигателя включают эксцентриситет вала ротора и размагничивание ротора. Эксцентриситет вала нарушает электромагнитный баланс и вызывает ненормальную вибрацию во время работы. Размагничивание ротора обычно вызывается перегревом двигателя, что приводит к снижению КПД двигателя и увеличению тока статора и температуры двигателя.

Основные неисправности в электрическом силовом приводе: короткое замыкание и обрыв цепи электрического моста, а также электроудары конденсатора источника питания.

К распространенным механическим неисправностям относятся чрезмерный износ, выкрашивание (образование вмятин на металлических поверхностях в точках контакта с высоким напряжением), заклинивание обратного канала и плохая смазка. Чрезмерный износ в основном возникает на шарико-винтовой паре и подшипниках с неподвижным концом. Серьезный износ шарико-винтовой пары может привести к выходу из строя всей системы ЭПЛА. Выкрашивание в основном вызывается поверхностной усталостью и увеличивает вибрацию ЭПЛА. Заклинивание обратного канала происходит из-за деформации возвратной трубы или мусора, прилипшего к возвратной трубе, что может привести к ухудшению фрикционного состояния ЭПЛА, выделению большого количества тепла и резкому снижению теплодинамических характеристик. Недостаточная и загрязненная смазка увеличивает трение и износ ЭПЛА.

2. МЕТОДЫ ДИАГНОСТИКИ НЕИСПРАВНОСТЕЙ ЭПЛА

2.1. Типы методов диагностики неисправностей ЭПЛА

Методы диагностики неисправностей ЭПЛА в основном делятся на методы, основанные на моделях, методы, управляемые данными (*Data-Driven*), в которых система рассматривается как черный ящик, и гибридные методы [18–20].

Принцип основанных на моделях методов диагностики неисправностей заключается в синхронном запуске моделей ЭПЛА и реальной системы ЭПЛА, затем оценивается разность между сигналами состояния математических моделей и реальными сигналами состояния ЭПЛА, которые измеряются различными датчиками и собираются системой сбора данных. Выходные невязки сигналов имитационных моделей и реальных систем используются для диагностики состояния работоспособности ЭПЛА.

Преимущества диагностики неисправностей на основе моделей заключаются в следующем [18].

• Создание точной модели существующей системы способствует пониманию физического механизма взаимодействий в ней. Моделирование неисправностей позволяет генерировать сигналы для обучения автоматизированных алгоритмов распознавания неисправностей, для тестирования и сравнения алгоритмов, диагностических и прогностических процедур и функций [21].

• Результаты, полученные методами диагностики отказов на основе модели, могут быть четко объяснены динамической моделью, а степень вырождения системы может быть получена путем сравнения значений отклонения параметров модели или невязок.

• Методы, основанные на модели, не требуют большого количества текущих данных, полученных в реальных условиях, для обучения алгоритмов диагностики неисправностей. Использование небольшого объема обучающих данных может дать хорошие результаты обучения и диагностики [22].

Однако основанные на моделях методы диагностики отказов для ЭПЛА имеют следующие недостатки.

• Для каждой из конкретных моделей диагностируемых систем необходимо разработать соответствующие математические модели, что является сложной задачей. Точные динамические модели часто требуют интенсивных вычислений, и это выдвигает высокие требования к вычислительной производительности.

• Механизм взаимодействия электромагнитной силы, термического напряжения и механического напряжения во время работы ЭПЛА сложен, и точную математическую модель создать трудно. В результате используются упрощенные модели, которые отражают характеристики физических систем приближенно. В этом случае основанные на модели методы диагностики неисправностей могут определить, произошла ли неисправность в ЭПЛА, но не могут точно определить неисправный компонент. Для более точной диагностики необходимо использовать подробные динамические модели каждого компонента.

Методы диагностики отказов, основанные на данных, не требуют создания сложных математических моделей ЭПЛА; они извлекают признаки для диагностики технического состояния ЭПЛА из сигналов, собранных с датчиков [23]. Важную роль в диагностике неисправностей ЭПЛА играют методы обработки сигналов. Качество исходных дан-

ных и корреляция между сигналами и неисправностями сильно влияют на эффективность алгоритмов диагностики. Условия работы ЭПЛА часто меняются даже во время нормальной работы, что делает сигналы состояния сильно нестационарными и непериодическими. Для устранения влияния различных условий эксплуатации применяется метод передискретизации, т. е. синхронизации сигналов с выбранными ключевыми сигналами. Например, в работе [24] в процессе извлечения признаков с помощью ряда методов обработки сигналов выявляются частоты неисправностей в сигнальных данных, синхронизированные с положением двигателя. При помощи методов извлечения и объединения признаков выбираются те из них, которые относятся к режиму отказа, а несвязанные признаки исключаются. При извлечении признаков для диагностики неисправностей ЭПЛА широко используется вейвлет-преобразование [25, 26].

Используя признаки, состояние работоспособности ЭПЛА можно определить при помощи классификатора для диагностики отказов. Если в классификатор подаются признаки, не связанные с ошибкой, это приведет к низкой скорости и плохому эффекту обучения. При помощи метода главных компонент можно выделить признаки классификации, связанные с неисправностью, и уменьшить размеры вектора признаков. Метод главных компонент позволяет характеризовать состояние процесса путем проецирования полученных данных в пространство меньшего размера. Этот метод уменьшения размерности сохраняет корреляцию между измерениями, оптимальным образом фиксируя изменчивость данных [27].

Однако методы диагностики ЭПЛА, основанные на данных, имеют следующие трудности в применении.

• Требуется большой объем данных при различных степенях и типах отказов для обучения алгоритмов диагностики. Эффективность диагностики сильно зависит от качества данных. Однако в большинстве случаев самолеты не могут летать с неисправными ЭПЛА, поэтому данные о неисправностях получить сложно. Отсутствие доступных экспериментальных данных является большой трудностью в исследованиях. Многие алгоритмы прошли только теоретическую проверку или были проверены только на данных, полученных на основе математического моделирования.

• При наличии серьезных шумовых помех или сложных систем обычно требуются усовершенствованные методы обработки сигналов и алгоритмы извлечения признаков. В результате методы диагностики на основе данных часто предъявляют высокие требования к вычислительной мощности системы.

• Методы, управляемые данными, обычно требуют высокой частоты дискретизации сигналов состояния. Таким образом, блок управления приводом должен иметь мощную вычислительную и запоминающую способность.

Для диагностики неисправностей ЭПЛА применяются также гибридные методы диагностики неисправностей, которые сочетают в себе преимущества как методов, основанных на данных, так и методов, основанных на моделях. Например, для генерации необходимых данных применяются методы, основанные на модели, а затем – методы, основанные на данных, для обработки сгенерированных данных и реализации диагностики неисправностей [28].

2.2. Диагностика неисправностей ЭПЛА на основе глубокого обучения

Традиционные методы машинного обучения широко применяются для диагностики неисправностей ЭПЛА. Подробный обзор этих методов приводится в работе [18]. Однако извлечение признаков в этих традиционных подходах, основанных на данных, осуществляется вручную. Эти процессы в значительной степени зависят от предварительных знаний, диагностического опыта и сложных методов преобразования сигналов, которые являются трудоемкими и отнимают много времени, а эффективность диагностики во многом зависит от выбранных характеристик неисправности. При наличии достаточных обучающих данных модели глубокого обучения позволяют автоматически обрабатывать исходные сигналы и реализовать комплексную интеллектуальную диагностику неисправностей. Но поскольку ЭПЛА обычно используются в высоконадежном и критически важном для безопасности оборудовании, получить сбалансированные данные о режимах отказа затруднительно [29].

В работе [30] для обнаружения и изоляции неисправностей ЭПЛА применяется модифицированная модель долгой краткосрочной памяти (англ. *Long Short-Term Memory*, LSTM); эффективность метода подтверждена открытыми данными NASA. Нейронная сеть долгой краткосрочной памяти представляет собой сеть глубокого обучения, предназначенную для изучения долгосрочных зависимостей, поскольку в ней может сохраняться информация в течение длительного времени. В работе [31] для точной диагностики неисправностей ЭПЛА объединили несколько автоэнкодеров

с шумоподавлением. Однако эти методы хорошо работают только при достаточном количестве данных и сбалансированных выборках, что трудно реализовать в большинстве сценариев диагностики неисправностей, связанных с ЭПЛА.

Для выделения признаков при несбалансированных данных используются сверточные нейронные сети. В работе [32] предложена двумерная сверточная нейронная сеть и оптимизированная модель на основе функции активации Softmax для диагностики шариковых винтов ЭПЛА с использованием сигналов тока двигателя, в результате улучшены извлечение и классификация признаков при различных рабочих нагрузках и в случаях с несбалансированными образцами. В работе [33] были использованы неконтролируемые параллельные данные и реализована диагностика ЭПЛА с помощью различных датчиков на основе сверточной нейронной сети. Однако эти методы не решают проблему диагностики в условиях малой выборки.

В работе [34] для диагностики неисправностей в условиях небольшого размера выборки на основе вибрационных сигналов предлагается использовать генеративно-состязательную сеть. Состязательные автоэнкодеры используются для преобразования автоэнкодеров в генеративно-состязательные сети. В статье [35] представлена генеративно-состязательная сеть на основе условно-вариационного автоэнкодера для решения проблемы несбалансированной выборки в различных условиях работы. В работе [29] для реализации надежной диагностики неисправностей для ЭПЛА с использованием только сигналов вибрации предлагается комплексный подход, основанный на данных, объединяющий возможности сверточной нейронной сети для извлечения признаков с возможностями полуконтролируемого обучения и генерации данных состязательного автоэнкодера при различных условиях работы и несбалансированных выборках. В статье [36] предложен метод обнаружения неисправности шарико-винтовой передачи, основанный на глубокой сети доверия. Использовались частотные спектры объединенного набора данных, собранных с нескольких датчиков.

Наличие избыточных данных увеличивает нагрузку на программное и аппаратное обеспечение. В работе [37] для обработки наблюдаемых данных и извлечения разреженных характеристик используется полууправляемый разреженный автоэнкодер, позволяющий повысить точность выделения неисправностей при одновременном сокращении наблюдаемых данных. Временны́е и пространственные взаимосвязи исследуются многоканальной LSTM-сетью для построения модели временны́х рядов, чтобы выполнять обнаружение неисправностей и их изоляцию на основе разницы между значениями параметров, которые измеряются датчиками, и значениями этих параметров, которые рассчитываются автоэнкодером. Результаты проверки подтверждают, что предлагаемый метод позволяет эффективно диагностировать неисправности ЭПЛА.

В работе [38] авторы объединили гибридную пространственную и временну́ю синхронизированную рекуррентную единицу на основе внимания с процедурами декомпозиции сезонно-трендовых данных и продемонстрировали хорошие результаты как в диагностике неисправностей, так и в прогнозировании неисправностей в ЭПЛА.

В работе [39] описывается имитационная модель ЭПЛА и анализируются типичные неисправности ЭПЛА.

Моделирование ЭПЛА разделено на три отдельные части в соответствии с его составом: синхронный двигатель с постоянными магнитами, редуктор и шариковый винт.

Синхронный двигатель с постоянными магнитами моделируется уравнениями

$$\begin{cases} u_d = R_a i_d + L\dfrac{di_d}{dt} - P_m\omega_m L i_q, \\ u_q = R_a i_q + L\dfrac{di_q}{dt} + P_m\omega_m L i_d + P_m\omega_m\psi_{f_m}, \\ T_L = T_e - J\dfrac{d\omega_m}{dt} - B\omega_m = 1{,}5P_m\psi_{f_m} i_q - J\dfrac{d\omega_m}{dt} - B\omega_m, \end{cases}$$

где u_d, u_q, i_d, i_q – эквивалентное напряжение и эквивалентный ток соответственно (в системе главных компонент ротора с координатами *d*, *q*); R_a – эквивалентное сопротивление обмотки катушки; L – эквивалентная индуктивность; P_m – число пар полюсов двигателя; ω_m – механическая угловая скорость ротора; ψ_{f_m} – эквивалентная магнитная цепь; T_e – выходной электромагнитный момент двигателя, J – эквивалентная инерция вращения ротора двигателя; B – коэффициент демпфирования ротора; T_L – комбинированный момент сопротивления нагрузки.

При игнорировании трансмиссионного зазора, момента трения и других влияющих факторов математическая модель редуктора имеет вид

$$\theta_g = \theta_m / N_i,$$

где θ_g – выходное угловое смещение редуктора; θ_m – угловое смещение выходного вала двигателя; N_i – передаточное отношение редуктора.

Если пренебречь зазором винта, деформацией, трением и другими влияющими факторами, математическая модель шарикового винта имеет вид

$$x_g = \frac{\theta_g}{2\pi} P_h,$$

где x_g – выходное смещение шарико-винтовой передачи, а P_h – ход шарико-винтовой передачи.

На основе этой модели для диагностики неисправности применяется метод с использованием нейронной сети SAE-BiLSTM; его структура представлена на рис. 1. Обучение сетей выполняется в автономном режиме с известными нормальными данными и данными об отказах. Обученные сети загружаются в бортовую систему для обеспечения онлайн-диагностики и обнаружения неисправностей.

Метод диагностики неисправностей ЭПЛА заключается в следующем.

• Данные собираются и предварительно нормализуются в диапазоне [0, 1].

• Выполняется обучение: сеть извлечения признаков на основе разреженного автоэнкодера (SAE) обучается выполнять адаптивное извлечение данных датчиков на уже собранном наборе данных, содержащем нормальные рабочие состояния и состояния неисправности, что обеспечивает снижение размерности и сжатие при сохранении важных признаков. После этого регрессор на основе сети BiLSTM (сеть BiLSTM состоит из нейронов LSTM и модели двунаправленной рекуррентной нейронной сети) обучается с использованием данных признаков нормального состояния, которые применяются для построения модели временных рядов и поиска разностей между расчетными и измеренными значениями нормальных и ошибочных данных. На основе полученных разностей и соответствующих типов ошибок классификатор на основе Softmax обучается для классификации ошибок.

• Для диагностики неисправностей применяются три сети, полученные в процессе обучения. Обработанные данные мониторинга сначала передаются через сеть SAE для уменьшения масштаба данных и извлечения признаков, затем при помощи сети BiLSTM вычисляются разности между

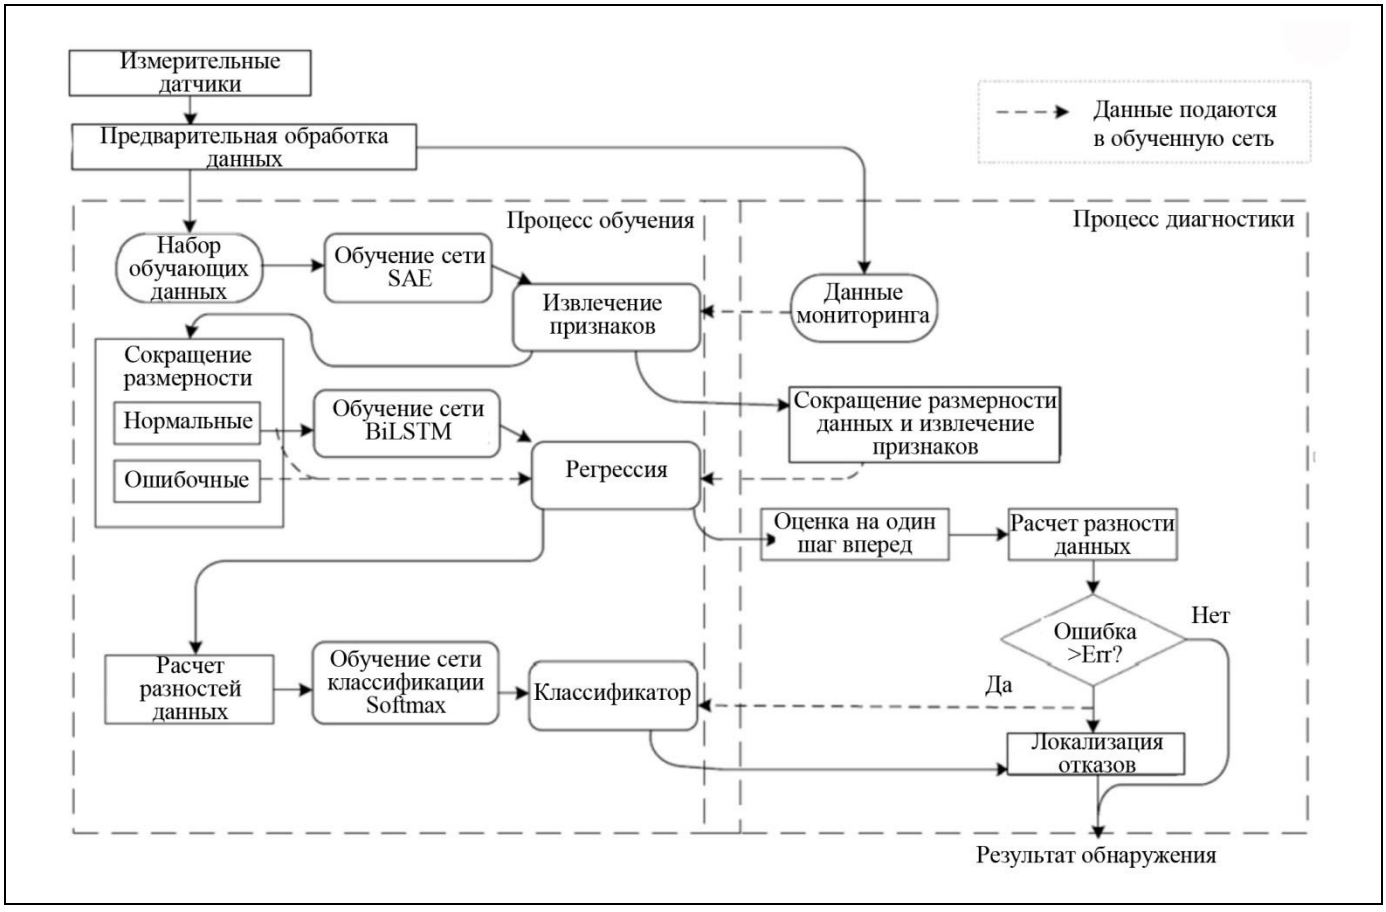

Рис. 1. Схема диагностики неисправностей ЭПЛА на основе глубокого обучения

одношаговой опережающей оценкой и измеренными данными, и если разности превышают пороговое значение, сообщается об ошибке, а данные о произошедшей ошибке передаются в сеть Softmax для классификации ошибки.

2.3. Диагностика неисправностей ЭПЛА на основе многомасштабной сверточной нейронной сети

В работе [14] для диагностики неисправностей ЭПЛА предлагается метод многомасштабной сверточной нейронной сети слияния признаков, который состоит из четырех последовательных этапов: многомасштабное преобразование, изучение признаков, объединение признаков и классификация неисправностей. Работа ЭПЛА осуществляется в сложных условиях, связанных с изменением скорости и нагрузки, при сильном шуме внешней среды. Внедрение многомасштабного преобразования в сверточную нейронную сеть позволяет улучшать разнообразие и взаимодополняемость характеристик, связанных с неисправностями.

Многомасштабное преобразование представляет собой выборку сигнала с разной степенью детализации. Для данного одномерного сигнала $\{x\}$ длины N несколько последовательных сигналов $\left\{y^{(k)}\right\}$ с разной степенью детализации создаются с помощью простого процесса понижения частоты дискретизации. На рис. 2 представлен сигнал в трех разных масштабах (Масштаб 1, Масштаб 2 и Масштаб 3).

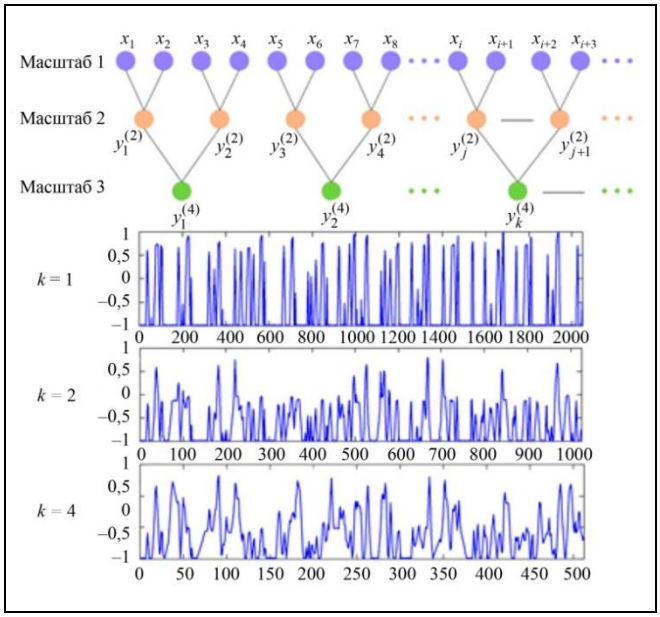

Рис. 2. Метод многомасштабной понижающей дискретизации сигнала

Можно получить несколько отфильтрованных сигналов с разными масштабами. Количество детализированных сигналов связано с деталями и тенденциями изучения признаков.

Математическое описание многомасштабной понижающейся дискретизации выглядит следующим образом:

$$y_j^{(k)} = \frac{1}{k} \sum_{i=(j-1)k+1}^{jk} x_i,\ 1 \le j \le \frac{N}{k},$$

где k – коэффициент масштабирования.

Для изучения признаков после получения сигналов $\left\{y^{(k)}\right\}(k=1,\ 2,\ 4)$ с разными масштабами дискретизации полученные сигналы параллельно проходят через пары сверточных слоев $\left(C1^{(k)}, C2^{(k)}, C3^{(k)}\right)$ и слоев объединения $\left(P1^{(k)}, P2^{(k)}, P3^{(k)}\right)$ для обучения в разных временны́х масштабах. В частности, для сигналов с разными масштабами дискретизации используются фильтры (ядра свертки) разных размеров, так что каждый параллельный сверточный слой на одном уровне может получать характеристики разных высоко- и низкочастотных признаков, тем самым улучшая диагностические характеристики модели.

Первые сверточные слои $\left(C1^{(1)}, C1^{(2)}, C1^{(4)}\right)$ имеют длину сигнала N, $N/2$, $N/4$ соответственно. Для каждой первой свертки размер соответствующего ядра свертки уменьшается по мере увеличения значения k, что способствует лучшему извлечению полезных признаков.

Для каждого сигнала $\left\{y^{(k)}\right\}(k=1,\ 2,\ 4)$ после слоев $C1^{(k)}$ и $P1^{(k)}$ генерируется определенное количество новых карт признаков. Затем эти карты признаков используются в качестве входных данных для слоя $C2^{(k)}$, операции повторяются и генерируются новые карты признаков. Точно так же, если предположить, что в слое $C3^{(k)}$ используются K ядер свертки, выходом слоя объединения $P1^{(k)}$ является K новых карт признаков:

$$q^{(k)} = [p_1,\ p_2, \ldots,\ p_K].$$

Окончательное представление признака q имеет три разных масштаба:

$$q = \left[q^{(1)}, q^{(2)}, q^{(4)}\right].$$

Следовательно, по сравнению с традиционным одномасштабным представлением, многомасштабное изучение признаков имеет больший диапазон охвата признаков, что способствует извлечению дополнительных признаков и обеспечивает лучший эффект для следующего шага классификации неисправностей.

В качестве эффективного механизма слияния признаков используется механизм внимания. Сеть может выборочно усиливать полезные функции для выявления ошибок и подавлять недействительные.

Для выполнения классификации используется комбинация полносвязного скрытого слоя и слоя Softmax. На вход полносвязного слоя подается вектор признаков q, полученный на предыдущем этапе. Скрытый слой использует ReLU в качестве функции активации, в выходном слое используется функция Softmax.

Пусть Y представляет собой метку категории состояния ЭПЛА. Предположим, что всего n категорий; т. е. для входной выборки x вероятность того, что она принадлежит к категории c, определяется следующим образом:

$$p\left(Y=c|x;\,\theta\right)=\operatorname{softmax}\left(\theta_c^{\mathrm{T}}x\right)=\frac{\exp\left(\theta_c^{\mathrm{T}}x\right)}{\sum\limits_{j=1}^{n}\exp\left(\theta_j^{\mathrm{T}}x\right)},$$

где $\theta=\left[\theta_1,\,\theta_2,\ldots,\,\theta_n\right]$ – параметр, который необходимо изучить в модели; $1/\sum\limits_{j=1}^{n}\exp(\theta_j^{\mathrm{T}}x)$ – нормированная функция, $\sum\limits_{j=1}^{n}P_j=1$.

Для любой заданной входной выборки многомасштабная сверточная нейронная сеть будет предсказывать результат. Для того чтобы предсказанное значение модели максимально соответствовало истинному, необходимо минимизировать расстояние между предсказанным значением и истинным значением, т. е. функцию потерь

$$L(\theta)=-\frac{1}{m}\left[\sum_{i=1}^{m}\sum_{k=1}^{K}I\left\{y_i=k\right\}\log\frac{\exp\left(\theta_k^{\mathrm{T}}x\right)}{\sum\limits_{j}^{K}\exp\left(\theta_j^{\mathrm{T}}x\right)}\right],$$

где m – количество проб или размер входной партии; $I\left\{\cdot\right\}$ – функция индекса:

$$I\left\{y_i=k\right\}=\begin{cases}1, \text{ если } y_i=k,\\ 0, \text{ если } y_i\neq k.\end{cases}$$

Чтобы минимизировать значение функции потерь модели, необходимо оптимизировать и настроить вес нейронной сети, и оптимизатор использует для этого алгоритм обратного распространения:

$$\theta^{*}=\arg\min_{\theta}L\left(f\left(x;\,\theta\right),\,y\right),$$

где θ^{*} – оптимальный параметр модели; $L(\cdot)$ – функция потерь; $f(\cdot)$ и y – выходное значение и целевое значение модели соответственно.

Авторы работы [14] приводят двумерную визуализацию процесса классификации (рис. 3), которая показывает, что сначала выборки различных категорий исходного сигнала перемешаны и неразделимы (рис. 3, *а*), по мере прохождения слоев выборки разделяются (рис. 3, *б–ж*) и после слоя Softmax располагаются далеко друг от друга (рис. 3, *з*).

В работе [14] приводятся экспериментальные результаты, которые показывают, что в сценариях с сильным шумом и переменными нагрузками предлагаемый метод имеет лучшую производительность, чем такие современные методы диагностики неисправностей, как сверточные нейронные сети с широкими ядрами первого уровня [40] и многомасштабные сверточные нейронные сети [41].

3. ПРОГНОЗИРОВАНИЕ ТЕХНИЧЕСКОГО СОСТОЯНИЯ ЭПЛА

3.1. Техническое обслуживание на основе прогнозирования

На работы по техническому обслуживанию ЛА приходится около 10–20 % общих эксплуатационных расходов. Оптимизация затрат на техническое обслуживание самолетов благодаря внедрению обслуживания на основе прогнозирования упоминается в многочисленных исследованиях [42–47].

Предполагается, что обслуживание на основе прогнозирования будет проводиться при необходимости в зависимости от технического состояния компонента с целью предупреждения неисправностей до их появления, а не по времени независимо от текущего состояния. Для реализации обслуживания на основе прогнозирования необходима упреждающая оценка технического состояния и прогнозирование оставшегося срока полезного использования компонентов и подсистем в реальном времени на основе моделей, на основе данных или с помощью гибридных методов [48]. Основные

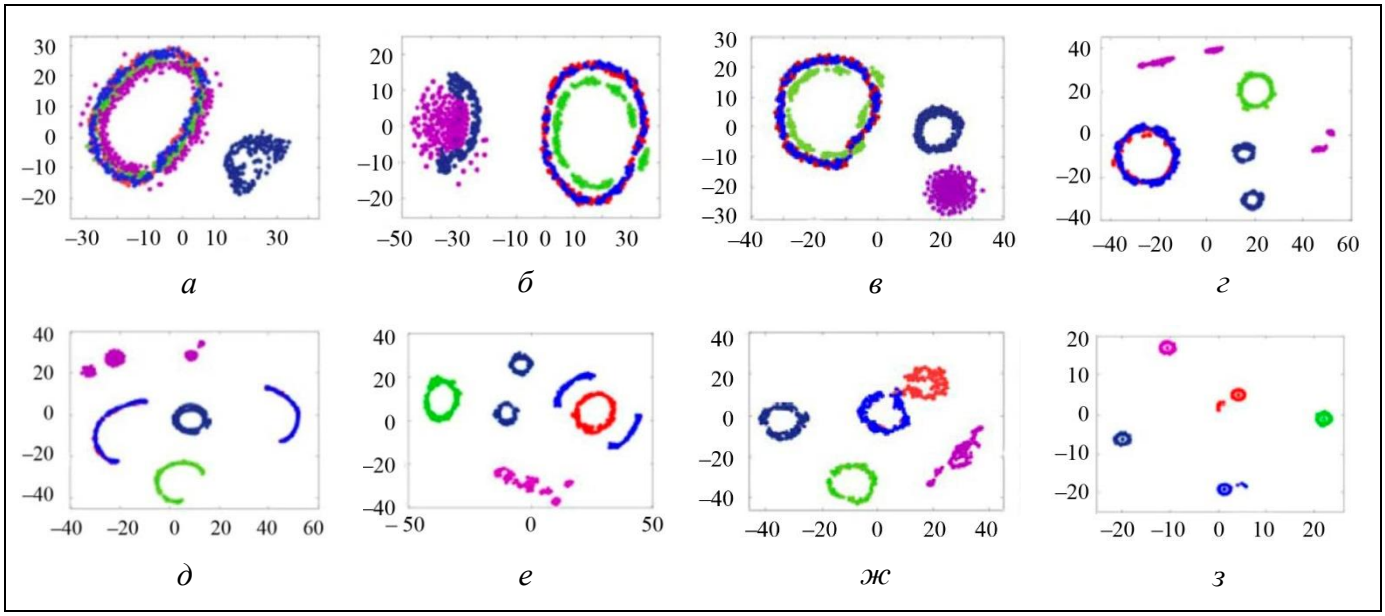

Рис. 3. Двумерная визуализация процесса классификации многомасштабной сверточной нейронной сети

преимущества и недостатки разных методов обсуждались в п. 2.1. В работе [49] предлагается метод раннего обнаружения и идентификации неисправностей ЭПЛА на основе модели. Предлагаемый метод прогнозирования способен идентифицировать аномальное поведение ЭПЛА при двух прогрессирующих отказах: частичном межвитковом замыкании фазы статора и статическом эксцентриситете ротора. Использование моделей для оценки технического состояния и прогнозирования оставшегося срока полезного использования на борту требует тщательной проверки этих моделей. В работе [9] описан испытательный стенд для экспериментальной проверки моделей ЭПЛА в номинальных условиях, а также при наличии зарождающихся механических неисправностей, таких как изменение трения и увеличение люфтов в редукторе.

Применение методов машинного обучения для прогнозирования технического состояния в авиации сопряжено с рядом проблем [50]. Эксплуатационные данные, генерируемые системой технического состояния ЛА, крайне несбалансированы, поскольку отказы компонентов ЛА происходят во время полетов чрезвычайно редко и данные смещены в сторону нормальной работы. В этом случае необходимы специальные методы анализа, способные противодействовать дисбалансу данных. Другая проблема заключается в отсутствии общедоступных наборов данных, что ограничивает исследования в этой области [46].

В работе [51] представлен метод обнаружения редких отказов для прогностического обслуживания самолетов с применением 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 (англ. *Bidirectional Gated Recurrent Unit*, BGRU) для прогнозирования следующего возникновения сбоя. 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.

В настоящее время в литературе рассматривается главным образом прогнозирование технического состояния и оставшегося срока полезного использования авиационных двигателей [52–55]. Для решения проблемы оценки оставшегося срока полезного использования был предложен ряд гибридных подходов, основанных на физических моделях и анализе данных. В зависимости от того, какой тип информации обрабатывается и как фрагменты информации объединяются, были предложены различные типы гибридных архитектур. На данный момент универсальной прогностической модели не существует и ее выбор зависит от конкретных характеристик отдельных рассматриваемых подсистем [56].

Для решения проблем в области прогнозирования технического состояния и оставшегося срока полезного использования ЭПЛА в настоящее время отсутствует достаточное количество реальных данных об отказах в условиях эксплуатации, поскольку использование ЭПЛА в ЛА в основном ограничивается системами, некритичными для безопасности, и отказы очень редки. Поэтому применяются главным образом методы на основе моделей.

3.2. Прогнозирование неисправностей ЭПЛА на основе метаэвристических алгоритмов

Авторы статьи [57] исследуют инструмент обнаружения и идентификации неисправностей ЭПЛА на основе модели с использованием генетического алгоритма. Предлагаемый подход тестировался для обнаружения нескольких наиболее распространенных отказов. Отмечается способность предлагаемой стратегии точно оценивать работоспособность системы при наличии нескольких режимов отказа, влияющих на одни и те же сигналы одновременно. Однако требуемое время вычислений делает стратегию пригодной для обнаружения и идентификации неисправностей ЭПЛА, выполняемых во время планового технического обслуживания, но не для оценки неисправностей в реальном времени.

В работах [3, 58, 59] авторы исследуют применение биоинспирированных метаэвристических алгоритмов для решения задачи обнаружения скрытых неисправностей, зарождающихся отказов и их прогрессирования в процессе эксплуатации с целью предотвращения потенциально опасных отказов типичного бортового ЭПЛА.

Из-за того, что отказы ЭПЛА редки и реальные данные получить сложно, авторы работы [3] использовали данные, полученные на основе моделирования: эталонной модели (англ. *reference model*, RM) с высокой точностью [60] и модели мониторинга (англ. *monitoring model*, MM), с низкой точностью, при помощи которой моделирование выполнялось почти в режиме реального времени [61]. Экспериментальная проверка моделей проводилась при помощи экспериментального испытательного стенда [9].

Моделировались наиболее критичные для ЭПЛА отказы: сухое трение, люфт, короткое замыкание, эксцентриситет ротора и дрейф пропорционального коэффициента усиления ПИД-регулятора. Отказы моделировались при помощи параметров отказов, каждый из которых связан с определенным отказом и для характеристики различных масштабов отказа принимает значение от 0 до 1. Путем изменения параметров отказов моделировалось поведение исполнительного механизма в различных условиях. Во время прогностической процедуры запускалась ММ с некоторым набором параметров отказов. Нахождение вектора параметров отказов, при которых разница между прогнозируемыми и фактическими тенденциями достаточно мала, позволяет определить, происходит ли сбой, какого рода сбой и каков его масштаб. Цель алгоритма оптимизации – подобрать такой вектор параметров отказов, который минимизирует целевую функцию. Целевая функция имеет вид

$$e_{tls} = \sum_i \frac{\left(I_{MM,i} - I_{RM,i}\right)^2}{\left(\frac{\Delta I_{RM,i}}{\Delta T}\right)^2 + 1} \cdot \Delta T,$$

где $I_{MM,i}$ и $I_{RM,i}$ – текущие выходы моделей ММ и RM соответственно в момент времени i. Оценивается квадратичная ошибка, характеризующая разницу между значениями выходов этих моделей, ΔT – шаг интегрирования.

Авторы сравнивают разные метаэвристические алгоритмы, основанные на биотехнологиях, а именно:

– дифференциальную эволюцию (англ. *Differential Evolution*, DE) – концепция этого алгоритма следует естественным эволюционным принципам [62, 63];

– оптимизацию роя частиц (англ. *Particle Swarm Optimization*, PSO) – наиболее часто используемый алгоритм роевого интеллекта, в котором рой способен определять оптимальные решения путем обмена информацией между частицами; в основу положено изучение движения птичьих стай или косяков рыб [64, 65];

– оптимизацию серого волка (англ. *Grey Wolf Optimization*, GWO) – алгоритм оптимизации, основанный на идее жесткой иерархии среди членов популяции. Особи с более высокими оценками приспособленности имеют большее влияние на процесс оптимизации [66, 67].

Результаты сравнения средней ошибки в процентах для каждого режима отказа для разных алгоритмов представлены на рис. 4. Для каждого вида отказа смоделированы два различных уровня величины в диапазоне от 0 до 1: высокий (0,75) и низкий (0,25).

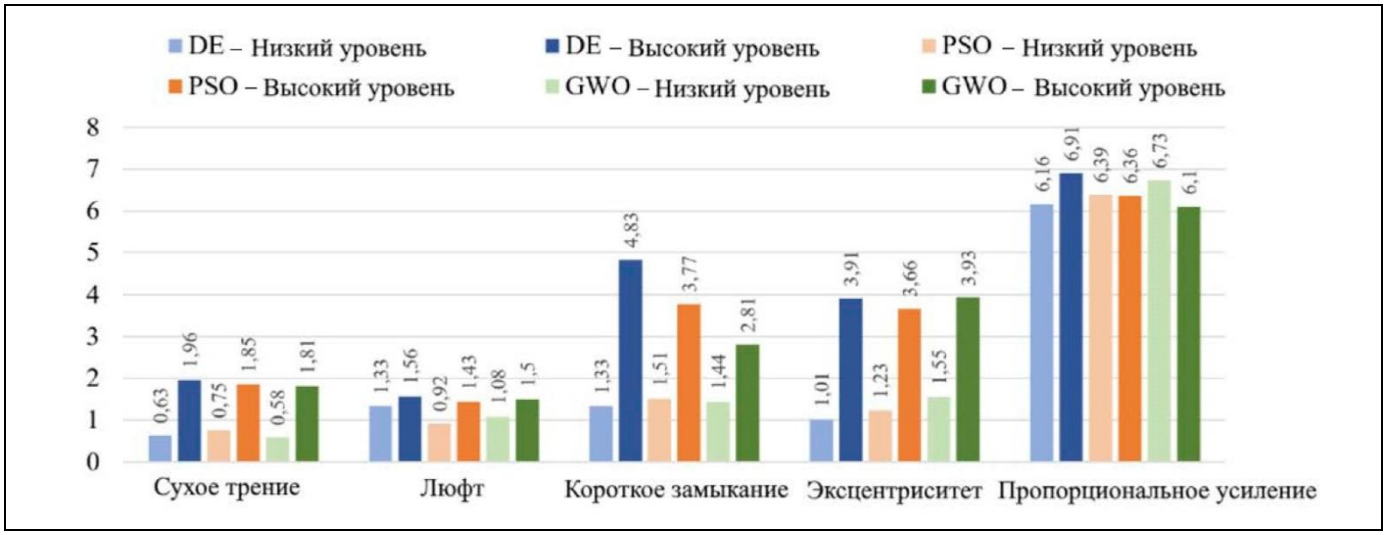

Рис. 4. Средняя ошибка в процентах для каждого режима отказа для разных алгоритмов

Алгоритм дифференциальной эволюции показывает немного меньшую ошибку, чем другие алгоритмы, для сигналов низкой интенсивности. Алгоритм оптимизации серого волка оказывается более точным для отказов высокого уровня (например, короткое замыкание и пропорциональное усиление). Алгоритм оптимизации роя частиц оказывается наиболее точным для ошибок люфта в целом, высокого статического эксцентриситета и низкого пропорционального усиления. Такие результаты свидетельствуют, что метаэвристические алгоритмы очень чувствительны к постановке задачи; ни один из исследуемых алгоритмов не способен превзойти другие в любой ситуации. Ведущим алгоритмом, обеспечивающим наилучшие результаты для случая множественных отказов, а также наиболее эффективным алгоритмом с точки зрения вычислительных затрат является алгоритм оптимизации роя частиц.

4. ОТЕЧЕСТВЕННЫЕ РАЗРАБОТКИ

Отечественные исследователи применяют подходы на основе нейронных сетей и машинного обучения для диагностики и прогнозирования технического состояния авиационных двигателей [68–70] и ЭПЛА [71–78].

Специалисты Пермского национального исследовательского политехнического университета в работе [71] приводят результаты комплексного анализа использования методов машинного обучения для диагностики асинхронных двигателей электропривода на лабораторном стенде. Задача определения исправности двигателя сводится к бинарной классификации для каждого типа неисправности, к поиску алгоритмов, обеспечивающих классификацию с большей точностью.

После проведенного анализа в качестве наиболее эффективного выбран подход к построению ансамбля классификаторов, включающий следующие методы:

– случайного леса, уменьшающий проблему переобучения;

– многослойный персептрон – класс искусственных нейронных сетей, продемонстрировавший способность находить приближенные решения для чрезвычайно сложных задач;

– градиентный бустинг, обрабатывающий категориальные признаки и нелинейности;

– усовершенствованную форму алгоритма градиентного бустинга, позволяющую повысить точность классификации.

Разработанная система классификации показала свою перспективность для промышленного внедрения благодаря низкой стоимости и высокой надежности.

Специалисты Московского авиационного института в работе [72] рассматривают нештатные ситуации, связанные с отказами приводов органов управления, и алгоритм обнаружения таких отказов, основанный на решении задачи идентификации модели движения ЛА и задачи классификации признаков отказной ситуации с применением нейросетевых методов. В работе анализируются три вида отказов приводов органов управления: потеря эффективности привода, «замораживание» привода в момент возникновения нештатной ситуации и сочетание этих двух типов отказов. При моделировании отказа привода управляющей поверхности производится модификация аэродинамических коэффициентов, содержащих значение

отклонения этой поверхности. Реализованы две схемы преобразования: когда переменная, содержащая отклонение управляющей поверхности, присутствует в аэродинамическом коэффициенте в явном и в неявном виде. Объектом модели диагностики является самолет-истребитель F-16. При моделировании полета в системе управления учитываются автопилоты угла атаки, тангажа и крена, отвечающие за выдерживание заданного углового положения ЛА. Модель движения представляет собой систему обыкновенных дифференциальных уравнений. Описывается реализация численного решения задачи Коши для этой системы уравнений методом Рунге – Кутты четвертого порядка. Данными наблюдений являются значения угловых скоростей и командных сигналов от каналов системы управления. Рассматривается подход, при котором распознавание признаков отказной ситуации производится на основании наблюдений за функциями кросс-корреляции угловых скоростей. Взаимосвязь между парами угловых скоростей можно оценить количественно и представить в виде функции. При возникновении отказа привода органа управления эта взаимосвязь нарушается. Для классификации отказов приводов используются нейросетевые модели функций кросс- и автокорреляции угловых скоростей.

В Центральном аэрогидродинамическом институте (ЦАГИ) разработан подход к испытаниям авиационных исполнительных механизмов для проверки работоспособности испытуемого привода при динамических внешних нагрузках, соответствующих различным режимам полета [73], который, получив развитие, в настоящее время применяется как для отладки алгоритмов диагностики неисправностей традиционных сервоклапанных гидроприводов, так и для ЭПЛА с использованием нейронных сетей. Целью экспериментальных испытаний электроприводов является выявление недостатков конструкции привода или настройки системы его управления. Испытания исполнительных механизмов, проводимые в ЦАГИ, можно квалифицировать следующим образом:

– изолированные испытания исполнительных механизмов и их элементов, а также сигнальных путей систем управления полетом;

– отработка исполнительных систем поверхности ЛА для управления полетом;

– тестирование контура управления «объект управления – система управления – исполнительное устройство».

Результаты этих испытаний могут быть использованы как формальное основание для выдачи первого сертификата летной годности.

В Институте проблем управления им. В.А. Трапезникова Российской академии наук (ИПУ РАН) совместно с ЦАГИ ведутся работы по разработке и исследованию технологий, методов и алгоритмов построения системы ранней диагностики электромеханических систем с использованием машинного обучения. Целью этих работ являются синтез и верификация алгоритмов машинного обучения для поиска и формализации закономерностей во взаимосвязях между контролируемыми параметрами, оценкой и прогнозом технического состояния электромеханических систем.

В работе [74] описана разработка и верификация на основании статических и динамических характеристик натурного образца математической модели рулевого сервопривода (СП) для БПЛА среднего радиуса действия взлетным весом 400 кг. Модель предназначена для создания системы ранней диагностики неисправностей СП. Сформулирована задача оценки состояния СП в виде задачи классификации на основе алгоритмов интеллектуального анализа данных. Предложена обобщенная схема формирования и анализа данных для оценки технического состояния СП.

В работах [75, 76] предложенная схема используется для построения алгоритма раннего обнаружения отказов ЭПЛА, связанных с изменением диссипативных потерь в механическом редукторе. Данные о работе ЭПЛА при взлете формировались с помощью математической модели и включали 12 параметров. На основе предлагаемого алгоритма отбора информативных признаков были отобраны четыре параметра в качестве входов нейронной сети и проведено обучение 50-ти нейронных сетей. Вычислительные эксперименты показали, что уменьшение количества входных параметров позволило уменьшить количество нейронов, повысить скорость обучения нейронных сетей и точность вычислений.

В докладе [77] представлена разработка алгоритмов поиска информативных признаков для прогнозирования технического состояния ЭПЛА. С этой целью применяются методы анализа временных рядов и генетические алгоритмы. Разработанные алгоритмы исследованы и верифицированы на данных, полученных с использованием математической модели ЭПЛА и в результате ресурсных стендовых испытаний бесколлекторного электродвигателя БПЛА.

Эффективность предлагаемого подхода для построения алгоритма определения технического состояния ЭПЛА на основе нейронных сетей, обеспечивающих формализацию закономерностей в данных, исследуется в работе [78]. Представлена

схема отбора информативных признаков на основе «оберточных» методов для обучения нейронной сети. Приводятся данные экспериментальных исследований определения технического состояния ЭПЛА (исправное, предаварийное, аварийное), связанных с изменением люфта и сухого трения.

ЗАКЛЮЧЕНИЕ

Представлен обзор зарубежных и отечественных исследований, посвященных методам диагностики неисправностей ЭПЛА на основе моделей, на основе данных и гибридных методов. Основные усилия исследователей направлены на методы глубокого обучения с целью анализа больших объемов данных, получаемых в процессе функционирования ЭПЛА. Применяя методы глубокого обучения, можно извлекать эффективные признаки неисправностей прямо из сигналов мониторинга и одновременно выполнять классификацию неисправностей.

Диагностика и классификация неисправностей являются лишь первыми шагами на пути к техническому обслуживанию ЭПЛА по состоянию на основе прогнозирования. Важную роль в обеспечении безопасности и надежности авиационных систем играют оценка технического состояния и прогнозирование оставшегося полезного срока использования в процессе эксплуатации, что позволяет своевременно предвидеть возможные отказы оборудования и предотвращать их.

Рассмотренные в обзоре подходы являются инновационными, они инициированы бурным развитием и значительными достижениями при практическом применении нейросетевых технологий и глубокого обучения в некоторых практических областях. Приведенный обзор литературы свидетельствует о большом интересе исследователей, особенно зарубежных, к применению таких подходов в области диагностики и прогнозирования неисправностей ЭПЛА, но пока только на стадии разработки и исследований. Результаты имитационного моделирования и экспериментов на стендах свидетельствуют о перспективности и необходимости дальнейшего развития методов, рассмотренных в обзоре, при этом отмечены также существующие трудности на пути их практического применения.

Одна из основных проблем при разработке систем управления техническим состоянием ЭПЛА по состоянию заключается в сложности получения необходимых данных для исследований, поскольку ЭПЛА пока используются в ЛА недостаточно широко, а их отказы достаточно редки. В настоящее время для исследований используются данные, полученные на основе моделирования и на испытательных стендах. На практике применение предлагаемых подходов может оказаться не столь эффективным из-за влияния реальных условий эксплуатации ЭПЛА и внешней среды.

ЛИТЕРАТУРА

1. *Garcia Garriga, A., Ponnusamy, S. S., Mainini, L.* A Multi-fidelity Framework to Support the Design of More-Electric Actuation // AIAA Aviation Forum. Multidisciplinary Analysis and Optimization Conference. – Atlanta, 2018. – DOI: 10.2514/6.2018-3741.
2. *Adu-Gyamfi, B.A., Good, C.* Electric aviation: a Review of Concepts and Enabling Technologies // Transportation Engineering. – 2022. – Vol. 9, no. 4 – DOI: 10.1016/j.treng. 2022.100134.
3. *Baldo, L., Querques, I., Dalla Vedova, M.D.L.,* et al. A Model-Based Prognostic Framework for Electromechanical Actuators Based on Metaheuristic Algorithms // Aerospace. – 2023. – Vol. 10, no. 3. – DOI: 10.3390/aerospace10030293.
4. *Li, J., Yu, Z., Huang, Y., Li, Z.* A Review of Electromechanical Actuation System for More Electric Aircraft // Proceedings of the IEEE International Conference on Aircraft Utility Systems (AUS). – Beijing, 2016. – P. 490–497.
5. *Annaz, F.Y., Kaluarachchi, M.M.* Progress in Redundant Electromechanical Actuators for Aerospace Applications // Aerospace. – 2023. – Vol. 10(9). – DOI: 10.3390/aerospace 10090787.
6. *Fu, S., Avdelidis, N.P.* Prognostic and Health Management of Critical Aircraft Systems and Components: An Overview // Sensors. – 2023. – Vol. 23, no. 19. – DOI: 10.3390/s23198124.
7. *Bertolino, A.C., De Martin, A., Jacazio, G., Sorli, M.* Towards a PHM System for Electromechanical Flight Control Actuators // Proceedings of I-RIM 2020. – Torino, 2020. – DOI: 10.5281/zenodo.4781001.
8. *Bertolino, A.C., De Martin, A., Jacazio, G., Sorli, M.* Design and Preliminary Performance Assessment of a PHM System for Electromechanical Flight Control Actuators // Aerospace. – 2023. – Vol. 10. – DOI: 10.3390/ aerospace10040335.
9. *Baldo L., Berri P.C., Matteo D. L.,* et al. Experimental Validation of Multi-fidelity Models for Prognostics of Electromechanical Actuators // Proceedings of the 7th European Conference of the Prognostics and Health Management Society. – Torino, 2022. – Vol. 7, no.1. – P. 32–42. – DOI: 10.36001.phme. 2022.v7i1.3347.
10. *Cai, B., Zhao Y., Liu, H., Xie, M.* A Data-Driven Fault Diagnosis Methodology in Three-Phase Inverters for PMSM Drive Systems // IEEE Transaction on Power Electronics. – 2017. – Vol. 32, no. 7. – P. 5590–5600.
11. *Sudhawiyangkul, T., Isarakorn, D.* Design and Realization of an Energy Autonomous Wireless Sensor System for Ball Screw Fault Diagnosis // Sensors and Actuators A Physical. – 2017. – Vol. 258. – P. 49–58.
12. *Chirico, A., Kolodziej, J.R.* Fault Detection and Isolation for Electro-Mechanical Actuators Using a Data-Driven Bayesian Classification // SAE International Journal of Aerospace. – 2012. – Vol. 5, no. 2. – P. 494–502.

13. *Chirico, A.J., Kolodziej, J.R.* A Data-driven Methodology for Fault Detection in Electromechanical Actuators // Journal of Dynamic Systems, Measurement and Control, Transactions of the ASME. – 2014. – Vol. 136, no. 4. – DOI: 10.1115/1.4026835.
14. *Song, Y., Du, J., Li, S.* Multi-Scale Feature Fusion Convolutional Neural Networks for Fault Diagnosis of Electromechanical Actuator // Applied Sciences. – 2023. – Vol. 13, no. 15. – Art. no. 8689. – DOI: 10.3390/app13158689.
15. *Wang, J., Zhang, Y., Luo, C., Miao, Q.* Deep Learning Domain Adaptation for Electro-Mechanical Actuator Fault Diagnosis Under Variable Driving Waveforms // IEEE Sensors Journal. – 2022. – Vol. 22, no. 11. – P. 10783–10793.
16. *Derrien, J.-C., Securite, S.D.* Electromechanical Actuator (EMA) Advanced Technologies for Flight Controls // 28-th International Congress of the Aeronautical Sciences (ICAS 2012). – Brisbane, 2012. – URL: https://icas.org/ICAS_ARCHIVE/ICAS2012/PAPERS/291.PDF.
17. *Qiao, G. Liu, G. Shi, Z.,* et al. A Review of Electromechanical Actuators for More/All Electric Aircraft Systems // Proceedings of Institution of Mechanical Engineers. Part C: Journal of Mechanical Engineering Science. – 2018. – Vol. 232, no. 22. – P. 4128–4151. – DOI: 10.1177/0954406217749869.
18. *Yin, Z, Hu, N., Chen, J.,* et al. A Review of Fault Diagnosis, Prognosis and Health Management for Aircraft Electromechanical Actuators // IET Electronic Power Applications. – 2022. – Vol. 16, no. 11. – P. 1249–1272. – DOI: 10.1049/elp2.12225.
19. *Jian, F., Mare, J.-C., Yongling, F.* Modelling and Simulation of Flight Control Electromechanical Actuators with Special Focus on Model Architecting, Multidisciplinary Effects and Power Flows // Chinese Journal of Aeronautics. – 2017. – No. 30 (1). – P. 47–65.
20. *Cui, Z., Jing, B., Jiao, X.,* et al. The Integrated-Servo-Actuator Degradation Prognosis Based on the Physical Model Combined With Data-Driven Approach // IEEE Sensors Journal. – 2023. – Vol. 23, no. 9. – P. 9370–9381. – DOI: 10.1109/JSEN.2023.3248323.
21. *Randall, R.B.* The Use of Simulation Models to Generate Data Corresponding to Faults in Machines // 8th International Conference on Reliability, Maintainability and Safety (ICRMS-2009). – Chendgu, 2009. – DOI: 10.1109/ICRMS.2009.5269971.
22. *Mazzoleni, M., Di Rito, G., Previdi, F.* Electromechanical Actuators for the More Electric Aircraft. – Cham: Springer, 2021. – 239 p. – DOI: 10.1007/978-3-030-61799-8.
23. *Hopf, K., Reifenrath, S.* Filter Methods for Feature Selection in Supervised Machine Learning Applications – Review and Benchmark // Cornell University. – arXiv: 2111.12140v1[cs.LG]. – 2021. – DOI: 10.48550/arXiv2111.12140.
24. *Chirico, A.J., Kolodziej, J.R., Hall, L.* A Data Driven Frequency Based Feature Extraction and Classification Method for EMA Fault Detection and Isolation // 5th Annual Dynamic Systems and Control Conference joint with the JSME 2012 11th Motion and Vibration Conference. – Houston, 2012. – DOI: 10.1115/DSCC2012-MOVIC2012-8749.
25. *Jing, J., Liu, H., Lu, C.* Fault Diagnosis of the Aircraft Electromechanical Actuation System Based on WPD-STFT Time Frequency Entropy and PNN // Vibroengineering Procedia. – Oct. 2017. – Vol. 14. – DOI: 10.21595/vp.2017.19247.
26. *Li, J., Meng, G., Xie, G., Jia, Y.* Sensor Fault Diagnosis Based on Wavelet Packet and SOM Neural Network // Chinese Journal of Sensors and Actuators. – 2017. – Vol. 30, no. 7. – P. 1035–1039. – DOI: 103969/j.issn.1004-1699.2017.07.011.
27. *Ruiz-Cárcel, C., Starr, A.* Data-Based Detection and Diagnosis of Faults in Linear Actuators // IEEE Transactions on Instrumentation and Measurement. – 2018. – Vol. 67. – Iss. 9. – P. 2035–2047. – DOI: 10.1109/TIM.2018.2814067.
28. *Narasimhan, S., Roychoudhury, I., Balaban, E., Saxena, A.* Combining Model-Based and Feature-Driven Diagnosis Approaches-A Case Study on Electromechanical Actuators // Proceeding of the 21-st International Workshop on Principles of Diagnosis Held Jointly with Annual Conference of the PHM Society. – Portland, 2010. – Vol. 2, no. 2. – DOI: 10.36001/phmconf.2010.v2i2.1936.
29. *Wang, C., Ding, Y., Ma, J.* An Adversarial Model for Electromechanical Actuator Fault Diagnosis under Nonideal Data Conditions // Neural Computing and Applications. – 2022. – Vol. 34, no. 1115. – P. 5883–5904. – DOI: 10.1007/s00521-021-06732-x.
30. *Yang, J., Guo, Y., Zhao, W.* Long Short-Term Memory Neural Network Based Fault Detection and Isolation for Electromechanical Actuators // Neurocomputing. – 2019. – Vol. 360. – P. 85–96. – DOI: 10.1016/j.neucom.2019.06.029.
31. *Yang, N., Shen, J., Jia, Y., Zhang, J.* Fault Diagnosis of Electromechanical Actuator Based on Deep Learning Network // 39th Chinese Control Conference (CCC). – Shenyang, 2020. – P. 4002–4006. – DOI: 10.23919/CCC50068.2020.9189666.
32. *Riaz, N., Shah, S.I.A., Rehman, F.,* et al. A Novel 2-D Current Signal-based Residual Learning with Optimized Softmax to Identify Faults in Ball Screw Actuators // IEEE Access. – 2020. – Vol. 8. – P. 115 299–115 313. – DOI: 10.1109/access.2020.3004489.
33. *Siahpour, S., Li, X., Lee, J.* Deep Learning-based Cross-sensor Domain Adaptation for Fault Diagnosis of Electromechanical Actuators // International Journal of Dynamics and Control. – 2020. – Vol. 8. – P. 1054–1062. – DOI: 10.1007/s40435-020-00669-0.
34. *Ding, Y., Ma, L., Ma, J.,* et al. A Generative Adversarial Network-based Intelligent Fault Diagnosis Method for Rotating Machinery under Small Sample Size Conditions // IEEE Access. – Vol. 7. – P. 149 736–149 749. – DOI: 10.1109/ACCESS.2019.2947194.
35. *Wang, Y., Sun, G., Jin, Q.* Imbalanced Sample Fault Diagnosis of Rotating Machinery Using Conditional Variational Auto-encoder Generative Adversarial Network // Applied Soft Computing Journal. – 2020. – Vol. 92, no. 7. – Art. no. 106333. – DOI: 10.1016/j.asoc.2020.106333.
36. *Zhang, L., Gao, H., Wen, J.,* et al. A Deep Learning-Based Recognition Method for Degradation Monitoring of Ball Screw with Multi-sensor Data Fusion // Microelectronics Reliability. – 2017. – Vol. 75. – P. 215–222. – DOI: 10.1016/j.microrel.2017.03.038.
37. *Yang, J., Guo, Y., Wanti, Z.* An Intelligent Fault Diagnosis Method for an Electromechanical Actuator Based on Sparse Feature and Long Short-Term Network // Measurement Science Technology. – 2021. – Vol. 32, no. 9. – DOI: 10.1088/1361-6501/abfbab.
38. *Zhang, X., Tang, L., Chen, J.* Fault Diagnosis for Electro-Mechanical Actuators Based on STL-HSTA-GRU and SM // IEEE Transaction on Instrumentation and Measurement. – 2021. – Vol. 70. – DOI: 10.1109/tim.2021.3127641.
39. *Tao, X., Guo, Y., Zhao, W.,* et al. Fault Detection and Isolation of Electromechanical Actuator Based on SAE-BiLSTM // The 13th Asia Conference on Mechanical and Aerospace Engineer-

ing (ACMAE 2022). Journal of Physics: Conference Series. – 2023. – Vol. 2472. – Art. no. 012031. – DOI: 10.1088/1742-6596/2472/1/012031.
40. *Zhang, W., Peng, G., Li, C.* A New Deep Learning Model for Fault Diagnosis with Good Anti-Noise and Domain Adaptation Ability on Raw Vibration Signals // Sensors. – 2017. – Vol. 17, no. 3. – DOI: 10.3390/s17020425.
41. *Jiang, G., He, H., Yan, J., Xie, P.* Multiscale Convolutional Neural Networks for Fault Diagnosis of Wind Turbine Gearbox // IEEE Transaction on Industrial Electronics. – 2018. – Vol. 66, no 4. – P. 3196–3207. – DOI: 10.1109/TIE.2018.2844805.
42. *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 Transactions on Instrumentation and Measurement. – 2023. – Vol. 72. – Art. no. 3505215. – DOI: 10.1109/TIM.2023.3236342.
43. *Rezaeianjouybari, B., Shang, Y.* Deep Learning for Prognostics and Health Management: State of the Art, Challenges, and Opportunities // Measurement. – 2020. – Vol. 163, no. 4. – DOI: 10.1016/j.measurement.2020.107929.
44. *Lei, Y., Li, N., Guo, L.*, et al. Machinery Health Prognostics: a Systematic Review from Data Acquisition to RUL Prediction // Mechanical Systems and Signal Processing. – 2018. – Vol. 104. – P. 799–834. – DOI: 10.1016.j.ymssp.2017.11.016.
45. *Berri, P.C., Dalla Vedova, M.D.L., Mainini, L.* Computational Framework for Real-time Diagnostics and Prognostics of Aircraft Actuation Systems // Computers in Industry. – 2021. – Vol. 132. – DOI: 10.1016/compind.2021.103523.
46. *Stanton, I., Munir, K., Ikram, A.* Predictive Maintenance Analytics and Implementation for Aircraft: Challenges and Opportunities // System Engineering. – 2022. – Vol. 26, no. 137. – DOI: 10.1002/sys.21651.
47. *Scott, M.J., Verhagen, W.J.C., Bier, 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. – DOI: 10.3390/s22187070.
48. *Ismail, M.A.A., Balaban, E., Windelberg, J.* Spall Fault Quantification Method for Flight Control Electromechanical Actuator // Actuators. – 2022. – Vol. 11, no. 29. – DOI: 10.3390/act11020029.
49. *Belmonte, D., Dalla Vedova, M.D.L., Maggiore, P.* Prognostics of Onboard Electromechanical Actuators: a New Approach Based on Spectral Analysis Techniques // International Review of Aerospace Engineering. – 2018. – Vol. 11, no. 3. – DOI: 10.15866/irease.v11i3.13796.
50. *Zhang, J., Tian, J., Li, M.*, et al. A Parallel Hybrid Neural Network with Integration of Spatial and Temporal Features for Remaining Useful Life Prediction in Prognostics // IEEE Transaction on Instrumentation and Measurement. – 2023. – Vol. 72. – DOI: 10.1109/TIM.2022.3227956.
51. *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.
52. *Hasib, A.A., Rahman, A., Khabir, M., Shawon, M.T.* An Interpretable Systematic Review of Machine Learning Models for Predictive Maintenance of Aircraft Engine // Cornell University. – arXiv:2309.13310v1[cs.LG]. – 2023. – DOI: 10.48550/arXiv.2309.13310.
53. *Khan, K., Sohaib, M., Rashid, A.* 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, no. 8. – DOI: 10.1007/s40430-021-03121-2.
54. *Boujamza, A., Lissane Elhaq, S.* Attention-Based LSTM for Remaining Useful Life Estimation of Aircraft Engines // IFACPapersOnLine. – 2022. – Vol. 55, no. 12. – P. 450–455. – DOI: 10.1016/j.ifacol.2022.07.353.
55. *Wang, C., Zhu, Z., Lu, N.* A Data-Driven Degradation Prognostic Strategy for Aero-Engine under Various Operational Conditions // Neurocomputing. – 2021. – Vol. 462, no. 3. – P. 195–207. – DOI: 10.1016/j.neucom.2021.07.080.
56. *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.ress.2021.107961.
57. *Aimasso, A., Berri, P.C., Dalla Vedova, M.D.* A Genetic-based Prognostic Method for Aerospace Electromechanical Actuators. International Journal of Mechanics and Control. – 2021. – Vol. 22, no. 2. – P. 195–206.
58. *Baldo, I., Vedova, M.D.L., Querques, I., Magglore, P.* Prognostics of Aerospace Electromechanical Actuators: Comparison between Model-based Meta-heuristic Methods // Journal of Physics: Conference Series. – 2023. – Vol. 2526, no. 1. – Art. no. 012073. – DOI: 10.1088/1743-6596/1/012073.
59. *Dalla Vedova, M.D.L., Berri, P.C., Re, S.* A Comparison of Bio-inspired Meta-hevristic Algorithms for Aircraft Actuator Prognostics // 29th European Safety and Reliability Conference. – Hannover, – 2019. – DOI: 10.3850/978-981-11-2724-3_0476-cd.
60. *Berri, P.C., Dalla Vedova, M.D., Maggiore, P.* A Lumped Parameter High Fidelity EMA Model for Model-Based Prognostics // 29th European Safety and Reliability Conference. – Hannover, 2019. – P. 1086–1093. DOI: 10.3850/978-981-11-2724-3_0480-cd.
61. *Berri, P.C., Dalla Vedova, M.D.L., Maggiore, P., Viglione, F.* A Simplified Monitoring Model for PMSM Servoactuator Prognostics // Proceedings of the MATEC Web of Conferences. – Osaka, 2018. – DOI: 10.1051/matecconf/201930404013.
62. *Randall, R.B.* The Use of Simulation Models to Generate Data Corresponding to Faults in Machines // 8th International Conference on Reliability, Maintainability and Safety (ICRMS-2009). – Chengdu, 2009. – DOI: 10.1109/ICRMS.2009.5269971.
63. *Ahmad, M.F., Isa, N.A.M., Lim, W.H., Ang, K.M.* Differential Evolution: A Recent Review Based on State-of-the-Art Works // Alexandria Engineering Journal. – 2022. – Vol. 61, no. 5. – P. 3831–3872. – DOI: 10.1016/j.aej.2021.09.013.
64. *Kennedy, J., Eberhart, R.* Particle Swarm Optimization // Proceedings of the IEEE International Conference on Neural Networks. – Perth, 1995. – P. 1942–1948. – DOI: 10.1109/ICNN.1995.488968.
65. *Darwish, A.* Bio-inspired Computing: Algorithms Review, Deep Analysis, and the Scope of Applications // Future Computing and Informatics Journal. – 2018. – Vol. 3, no. 2. – P. 231–246. – DOI: 10.1016/j.fcij.2018.06.001.
66. *Mirjalili, S., Mirjalili, S.M., Lewis, A.* Grey Wolf Optimizer // Advances in Engineering. – 2014. – Vol. 69. – P. 46–61. – DOI: 10.1016/j.advengsoft.2013.12.007.

67. *Kumar, V., Kumar, D.* An Astrophysics-inspired Grey Wolf Algorithm for Numerical Optimization and its Application to Engineering Design Problems // Advances in Engineering Software. – 2017. – Vol. 112. – P. 231–254. – DOI: 10.1016/advengsoft.2017.05.008.
68. *Егоров И.В., Соколов М.П.* Сравнение эффективности нейросетевых алгоритмов с методами факторного анализа при диагностировании технического состояния ГТД // Научный вестник МГТУ ГА. Серия «Эксплуатация воздушного транспорта и ремонт авиационной техники». – 2007. – № 123. – С. 89–95. [*Egorov, I.V., Sokolov, M.P.* Sravnenie efektivnosti neirosetevykh algoritmov s metodami faktopnogo analiza pri diagnostirovanii tekhnicheskogo sostoyaniya // Nauchnyj vestnik MGTU GA. Seriya «Ekspluatatsiya vozdushnogo transporta I remont aviatsionnoj tekhniki». – 2007. – No. 123. – P. 89–95. (In Russian)].
69. *Соколов М.П., Земсков А.А., Куц М.С.* Тренды технического диагностирования силовых установок и трансмиссий воздушных судов // Транспортное, горное и строительное машиностроение: наука и производство. – 2022. – № 15. – С. 37–46. [*Sokolov, M.P., Zemskov, A.A., Kuts, M.S.* Trendy tekhnicheskogo diagnostirovaniya silovykh ustanovok i transmissij vozdushnykh sudov // Transportnoe, gornoe i stroitel'noe mashinostroenie: nauka i proizvodstvo. – 2022. – No. 15. – P. 37–46. (In Russian)]
70. *Mikhailov, A., Karavay, M., Farhadov, M.* Inverse Sets in Big Data Processing // Proceedings of the 11th IEEE International Conference on Application of Information and Communication Technologies (AICT2017). – Moscow, 2017. – Vol. 1. – P. 40–43.
71. *Сальников С.В., Солодкий Е.М., Вишняков Д.Д.* и др. Диагностика асинхронного двигателя на основе машинного обучения // Международная конференция по мягким вычислениям и измерениям. – Санкт-Петербург, 2023. – Т. 1. – С. 295–300. [*Sal'nikov, S.V., Solodkij, E.M., Vishnyakov, D.D.*, et al. Diagnostika asinkhronnogo dvigatelya na osnove mashinnogo obucheniya //Mezhdunarodnaya konferentsiya po myagkim vychisleniyam I izmereniyam. – Saint Petersburg, 2023. – Vol. 1. – P. 295–300. (In Russian)]
72. *Козлов Д.С., Тюменцев Ю.В.* Нейросетевые методы обнаружения отказов датчиков и приводов летательного аппарата // Труды МАИ. – 2012. – Вып. 52. – С. 2. [*Kozlov, D.S., Tiumentsev, Y.V.* Nejrosetevye metody obnaruzheniya otkazov datchikov i privodov letatel'nogo apparata // Trudy MAI. – 2012. – Vol. 52. – P. 2. (In Russian)]
73. *Erofeev, E., Khaletskiy, L., Skryabin, A., Steblinkin, A.* Methodologies and test-rig configurations for the experimental improvement of flight control actuation systems // Recent Advances in Aerospace Actuation Systems and Component. Conference proceedings. – Toulouse, 2018. – P. 109–116.
74. *Вересников Г.С., Скрябин А.В., Гуцевич Д.Е.* Разработка математической модели для исследования алгоритмов оценки и прогноза технического состояния сервопривода БЛА // Известия ЮФУ. Технические науки. – 2019. – № 7. – С. 170–181. [*Veresnikov, G.S., Skryabin, A.V., Gutsevich, D.E.* Razrabotka matematicheskoj modeli dlya issledovaniya algoritmov otsenki I prognoza tekhnicheskogo sostoyaniya servoprivoda BLA // Izvestiya YUFU. Tekhnicheskie nauki. – 2019. – No. 7. – P. 170–181. (In Russian)]
75. *Veresnikov, G.S., Skryabin, A.V., Bazhenov, S.G.* The Development of Algorithms for EMA Fault Early Detection System // Proceedings of the 32th Congress of the International Council of the Aeronautical Sciences. – Shanghai, 2020. – URL: https://www.icas.org/ICAS_ARCHIVE/ICAS2020/data/preview/ICAS2020_0239.htm.
76. *Veresnikov, G.S., Lebedev, V.G., Ogorodnikov, O.V., Golev, A.V.* Fault Detection Technique for Electromechanical Actuator of the Aircraft Using Neural Networks // Lecture Notes in Mechanical Engineering. – Cham: Springer, 2021. – P. 519–528.
77. *Вересников Г.С., Скрябин А.В.* Алгоритмы поиска информативных признаков для прогнозирования технического состояния электромеханического привода // Тр. 14-й международной конференции «Управление развитием крупномасштабных систем» (MLSD-2021). – Москва, 2021. – С. 1389–1397. [*Veresnikov, G.S., Skryabin, A.V.* Feature Selection Algorithms for Forecasting Technical Condition of Electromechanical Actuator // Proceedings of the 14th International Conference «Management of Large-Scale System Development» (MLSD). – Moscow, 2021. – URL: https://ieeexplore.ieee.org/document/9600182/.
78. *Вересников Г.С., Скрябин А.В.* Диагностика неисправностей смешанного типа в редукторе электромеханического привода летательного аппарата с использованием нейронных сетей // Тр. 15-й Международной конференции «Управление развитием крупномасштабных систем» (MLSD-2022). – Москва, 2022. – С. 1116–1122. [*Veresnikov, G.S., Skryabin, A.V.* Diagnostics of Mixed Type Failures in the Aircraft Electromechanical Actuator Gear by Using Neural Networks // Proceedings of the 15th International Conference Management of Large-Scale System Development (MLSD). – Moscow, 2022. – URL: https://ieeexplore.ieee.org/document/9600182.

Статья представлена к публикации руководителем РРС В.Ю. Столбовым.

Поступила в редакцию 16.02.2024,
после доработки 07.03.2024.
Принята к публикации 23.04.2024.

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 год. Кулида Е. Л., Лебедев В. Г.

Эта статья доступна по лицензии Creative Commons «Attribution» («Атрибуция») 4.0 Всемирная.

MODERN APPROACHES TO PROGNOSTICS AND HEALTH MANAGEMENT OF AN AIRCRAFT ELECTROMECHANICAL ACTUATOR

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. In connection with implementing the concept of electric airplanes, it is necessary to ensure the high reliability of electromechanical actuators (EMAs) as important components of aviation systems. The structural composition of an EMA and the types of its faults are considered. Fault diagnosis methods based either on EMA modeling or the analysis of signals received during EMA operation, as well as hybrid methods combining both these approaches, are reviewed. The advantages, disadvantages, and difficulties in applying these approaches are investigated. Special attention is paid to EMA diagnosis methods based on deep learning, which process signals in automatic mode and implement complex fault diagnosis. The concept of aircraft equipment health management (in particular, EMA health management) is presented based on assessing the technical condition and prognosticating the remaining useful life in order to prevent faults before their occurrence. Several hybrid approaches with prognostics are highlighted to solve the aircraft health management problem. Finally, Russian R&D results in the field of machine learning-based aviation health management are reviewed.

Keywords: aircraft, electromechanical actuator (EMA), fault diagnosis, health management, prognostics.

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