

Алгоритм диагностики электромеханического привода летательного аппарата с использованием полносвязной нейронной сети типа «автокодировщик»

Г.С. ВЕРЕСНИКОВ,
д-р техн. наук,
Г.М. АВХИМЕНКО,
А.В. СКРЯБИН,
канд. техн. наук
(ИПУ РАН, Москва),
В.И. ГОНЧАРЕНКО,
д-р техн. наук
(МАИ, Москва),
Ю.Г. МИХАЙЛОВ,
канд. техн. наук
(НИУ МИЭТ, Москва),
Д.Н. СОБОЛЕВ
(ИПУ РАН, Москва)
vladimirgonch@mail.ru

Предлагается алгоритм, позволяющий анализировать техническое состояние электромеханического привода рулевой поверхности беспилотного летательного аппарата с использованием моделей машинного обучения, предназначенных для обнаружения аномалий и решающих известную задачу обнаружения новизны в наблюдаемых данных, которая интерпретируется как неисправность контролируемого объекта. Вычислительные эксперименты проведены на данных, полученных в результате моделирования работы электромеханического привода. Рассмотрены неисправности, описан способ разделения данных на обучающую и тестовые выборки. Выбрана архитектура полносвязной нейронной сети типа «автокодировщик» для решения задачи обнаружения аномалий. Рассмотрены вопросы выделения диагностических признаков и описана методология их извлечения из временных рядов. Приведены оценки эффективности разработанного алгоритма диагностики на разных видах тестовых выборок и выполнен анализ полученных результатов.

Обнаружение аномалий, автокодировщик, электромеханический привод, диагностика технического состояния, нейронная сеть

Современные беспилотные летательные аппараты (БЛА) широко применяются во многих сферах – сельском хозяйстве, природоохранной деятельности, строительстве, здравоохранении, при добыче полезных ископаемых. Ключевыми типовыми элементами системы управления БЛА самолетного типа являются электромеханические приводы, безотказное функционирование которых критически важно для безопасного полета [1, 2]. В связи с этим диагностика технического состояния электромеханического привода имеет важное практическое значение при эксплуатации беспилотных авиационных систем.

Увеличение сложности, многофункциональности и стоимости БЛА обуславливает потребность в разработке методов раннего обнаружения развивающихся неисправностей их электромеханического привода. В качестве решения предлагается применение методов машинного обучения, которые наряду с базами знаний [3] демонстрируют потенциал для интеграции в системы диагностики для повышения точности и оперативности оценки технического состояния электромеханического привода БЛА. Методы машинного обучения позволяют обрабатывать большие объемы информации, выявляя скрытые закономерности и аномалии, что можно эффективно применять для прогнозирования и предотвращения потенциальных отказов в работе электромеханического привода [4].

Методы для разработки алгоритмов технической диагностики можно условно подразделить на три базовые группы [5]: основанные на моделях [6]; основанные на данных [7]; гибридные, являющиеся комбинацией первых двух [8].

Применение методов, основанных на моделях, предполагает воспроизведение типовых процессов, которые наблюдаются при эксплуатации контролируемого объекта. Результаты сравнения модельных и фактических данных являются основой принятия решений в алгоритмах диагностики. При этом требует решения сложная проблема создания корректных математических моделей, адекватно учитывающих особенности и внешние условия функционирования контролируемого объекта. К часто применяемым методам, основанным на моделях, относятся фильтр Калмана и фильтр частиц с разнообразными модификациями и расширениями [9, 10].

Методы, основанные на данных, используют принципы обучения с учителем и без учителя [11]. При диагностике технических объектов обучение с учителем предполагает решение задачи классифика-

ции, а обучение без учителя – задачи обнаружения аномалий. При решении задачи классификации требуется обучающая выборка по всем классам технического состояния контролируемого объекта. Вместе с тем накопление репрезентативных данных по рассматриваемым неисправностям требует значительных финансовых и временных затрат. В задаче обнаружения аномалий модели, входящие в алгоритмы диагностики, строятся на основе обучающей выборки, соответствующей нормальному техническому состоянию контролируемого объекта. Построенные модели могут указать на аномальность анализируемого вектора. Аномальные векторы отражают закономерности функционирования контролируемого объекта, которые отличаются от наблюдаемых в обучающей выборке. В результате обеспечивается формирование информации о наличии неисправностей.

Для построения алгоритма диагностики электромеханического привода БЛА на основе моделей обнаружения аномалий используется полносвязанная нейронная сеть типа «автокодировщик». Применение автокодировщиков для обнаружения аномалий особенно актуально при необходимости анализа сложных и динамически изменяющихся данных, когда нецелесообразно рассматривать все возможные сценарии развития неисправностей контролируемого объекта. Алгоритмы на основе автокодировщиков способны адаптироваться и находить новые закономерности, что можно использовать для создания интеллектуальных обучающихся систем. Благодаря данным преимуществам автокодировщики широко применяются в задачах диагностики технических объектов [12–15].

В рамках проведенных исследований разработан алгоритм диагностики, который обнаруживает аномалии в данных, отражающих работу электромеханического привода при управлении рулевыми поверхностями БЛА. Алгоритм принимает на вход множество временных рядов, образованных значениями контролируемых параметров, а на выходе формирует заключение о техническом состоянии электромеханического привода. Далее рассматриваются вопросы подготовки выборок данных, формирования признакового пространства и построения моделей обнаружения аномалий с использованием методов машинного обучения, анализируется эффективность разработанного алгоритма диагностики электромеханического привода БЛА.

Для формирования исходных данных, которые являются основой создания модели обнаружения аномалий, входящей в алгоритм диагностики, применяется математическая модель, позволяющая воспроизвести рабочие процессы в электромеханическом приводе БЛА самолетного типа с учетом нагрузки и трех возможных неисправностей, задаваемых следующими параметрами (далее – параметры деградации): люфт, Н·м, – совокупный зазор в контактирующих парах редуктора; сухое трение, град, – момент силы постоянной величины, который оказывает сопротивление вращению вала; вязкое трение, Н·м/град/с, – момент силы, прямо пропорциональный скорости вращения вала (демпфирование), отражает степень смазки деталей.

Модель электромеханического привода БЛА верифицирована по статическим и динамическим характеристикам, полученным при экспериментальных исследованиях натурального привода, что делает возможным адаптацию разработанных моделей поиска аномалий в бортовых диагностических системах. С использованием результатов анализа механических и логарифмических амплитудно-фазовых частотных характеристик определена значимость и установлены границы параметров деградации и внешних факторов, определяющих агрегированные состояния электромеханического привода. Структура модели позволяет применять ее для получения данных электромеханического привода БЛА различных типов посредством настройки параметров контроллера, электродвигателя и редуктора. При этом алгоритмы диагностики, основанные на машинном обучении, требуется адаптировать под конкретный тип электромеханического привода. Проблемы удаления одного или нескольких ключевых признаков из входного пространства и искажения данных с датчиков являются предметом дальнейших исследований, направленных на построение ансамблевых моделей выявления аномалий.

Рассматривается циклограмма работы электромеханического привода хвостового оперения при выполнении режима полета, соответствующего маневру «вираж». Выполнение множества сеансов моделирования при варьировании параметров деградации позволяет сформировать выборки, которые содержат информацию о работе электромеханического привода БЛА в различных технических состояниях.

В рамках одного сеанса моделирования генерируется множество временных рядов, которые имитируют результат динамики изменения контролируемых параметров, соответствующих измеренным сигналам датчиков в электромеханическом приводе БЛА.

Схема расположения датчиков для мониторинга работы электромеханического привода представлена на рис. 1. Здесь: 1–12 – порядковые номера контролируемых параметров.

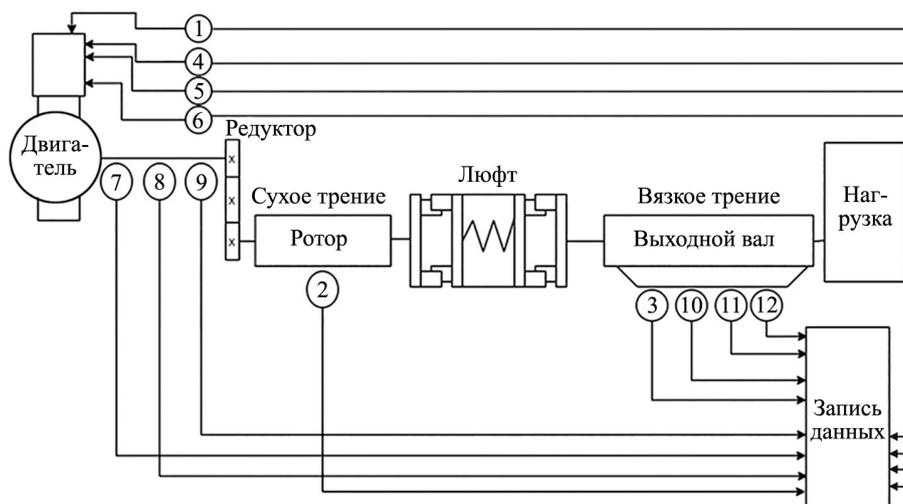


Рис. 1

Частота дискретизации при регистрации значений контролируемых параметров с использованием математической модели составляет 100 Гц. Один сеанс моделирования отражает работу электромеханического привода в течение 7 с. Контролируемые параметры электромеханического привода БЛА, значения которых образуют временные ряды, – управляющий сигнал (угол поворота), град; угол поворота ротора, град; угол поворота вала, град; напряжение тока, В; сила тока, А; мощность тока, Вт; скорость вращения ротора, об/мин; крутящий момент ротора, Н·м; мощность ротора, Вт; скорость вращения выходного вала, об/мин; крутящий момент выходного вала, Н·м; мощность выходного вала, Вт.

Для управления сеансами моделирования по параметрам деградации применяется полный факторный эксперимент, в результате которого формируется расчетная сетка, включающая всевозможные комбинации выделенных равномерным разбиением значений люфта, сухого трения и вязкого трения. Каждая точка расчетной сетки соответствует одному сеансу моделирования и одновременно элементу общей выборки, характеризующей работу электромеханического привода БЛА во всех рассматриваемых технических состояниях.

Для синтеза и оценки эффективности алгоритма диагностики электромеханического привода БЛА на основе модели обнаружения аномалий формируются обучающая, валидационная (контроль обучения нейронной сети) и несколько видов тестовых выборок. Тестовая выборка содержит нормальный и аномальные наборы данных, соответствующие исправному и неисправному техническому состоянию электромеханического привода. Поскольку рассматривается три параметра деградации, каждый из которых качественно может характеризовать два вида технического состояния электромеханического привода БЛА, формируется семь аномальных наборов данных. Эти наборы данных отражают неисправности по одному параметру деградации, одновременно двум из трех или по всем трем. Такая структура тестовой выборки позволяет оценить качество распознавания отдельных неисправностей и их комбинаций.

Количественное описание перечисленных выборок с указанием технического состояния по каждому параметру деградации приводится в табл. 1. Исправное состояние электромеханического привода БЛА обозначается нулем, неисправное – единицей.

Процесс построения моделей обнаружения аномалий на основе обучающей выборки включает этапы извлечения диагностических признаков и обучения полносвязной нейронной сети типа «автокодировщик».

При выполнении приведенных этапов диагностические признаки, которые извлекаются из временных рядов, образуют входной вектор нейронной сети и одновременно определяют алгоритмы преобразования данных перед ее обучением и использованием.

Таблица 1

Выборка	Вязкое трение	Сухое трение	Люфт	Количество наборов
Обучающая	0	0	0	5040
Валидационная	0	0	0	515
Тестовая:				
- нормальный набор	0	0	0	517
- аномальный набор 1	0	0	1	1536
- аномальный набор 2	0	1	0	2992
- аномальный набор 3	0	1	1	2176
- аномальный набор 4	1	0	0	1452
- аномальный набор 5	1	0	1	1056
- аномальный набор 6	1	1	0	2057
- аномальный набор 7	1	1	1	1496

Рационально сформированное множество диагностических признаков обеспечивает эффективность применения методов машинного обучения за счет упрощения задачи поиска и формализации закономерностей, позволяющих обнаруживать аномалии в работе электромеханического привода БЛА. В работе исследовался следующий набор признаков:

- разность между углом поворота ротора и выходного вала при установившемся значении после завершения маневра;
- затраченная электрическая энергия;
- положение выходного вала при достижении минимума траектории;
- время выполнения маневра до достижения минимума траектории;
- среднее значение пика электрической мощности после достижения минимума траектории;
- максимальное значение пика мгновенной электрической мощности после достижения минимума траектории;
- медианное значение пика мгновенной электрической мощности после достижения минимума траектории;
- средняя разность между углом поворота ротора и выходного вала;
- максимальная разность между углом поворота ротора и управляющим сигналом;
- угловой путь вала до достижения минимума траектории;
- количество пиков мощности тока после достижения минимума траектории.

В качестве одного из основных диагностических признаков был выбран модуль разности угла поворота ротора и выходного вала при достижении установившегося значения после завершения маневра. Вычислительные эксперименты показали, что указанный признак позволяет повысить точность определения технического состояния электромеханического привода, связанного с изменением люфта. Для обеспечения диагностики электромеханического привода по сухому трению в признаковое пространство добавлена работа электрического тока, при расчете которой используется интеграл мощности тока по времени [16]. Исследование сформированных выборок показало, что чем выше момент сухого трения, тем больше работы совершает электрический ток при воспроизведении электромеханическим приводом маневра типа «вираж». Для обнаружения аномалий в работе электромеханического привода БЛА по вязкому трению в признаковое пространство вводится совокупность статистических признаков.

Алгоритм диагностики электромеханического привода БЛА создается на основе полносвязной нейронной сети типа «автокодировщик», принимающей на вход рассмотренные признаки. Базовая архитектура автокодировщика состоит двух частей – энкодера и декодера (кодировщика и декодировщика). Входной вектор признаков подается в энкодер, который сжимает данные в латентное пространство, сохраняя только наиболее значимую информацию. Этот процесс позволяет выделить ключевые характеристики штатного функционирования электромеханического привода БЛА. После сжатия данные передаются в декодер, который восстанавливает исходные признаки. Восстановленный таким образом вектор признаков называется реконструированным, а процесс восстановления – реконструкцией.

Нейронная сеть типа «автокодировщик» обучается на данных, соответствующих штатной работе электромеханического привода БЛА. При возникновении аномалий (неисправностей) реконструированный вектор признаков \tilde{X}_k будет значительно отличаться от исходного X_k . Ошибка реконструкции вектора признаков при работе электромеханического привода БЛА в неисправном техническом состоянии будет больше, чем в исправном. Эта ошибка служит индикатором наличия аномалии при использовании стандартного порогового решающего правила. Если ошибка $L(X, \tilde{X})$ реконструкции превышает заданное пороговое значение ε , то предполагается неисправность электромеханического привода:

$$L(X, \tilde{X}) \geq \varepsilon. \quad (1)$$

Таким образом, формируется модель обнаружения аномалий, которая составляет основу алгоритма диагностики электромеханического привода БЛА.

Архитектура полносвязной нейронной сети типа «автокодировщик», которая была выбрана для сформированного признакового пространства в результате расчетных исследований, представлена на рис. 2.

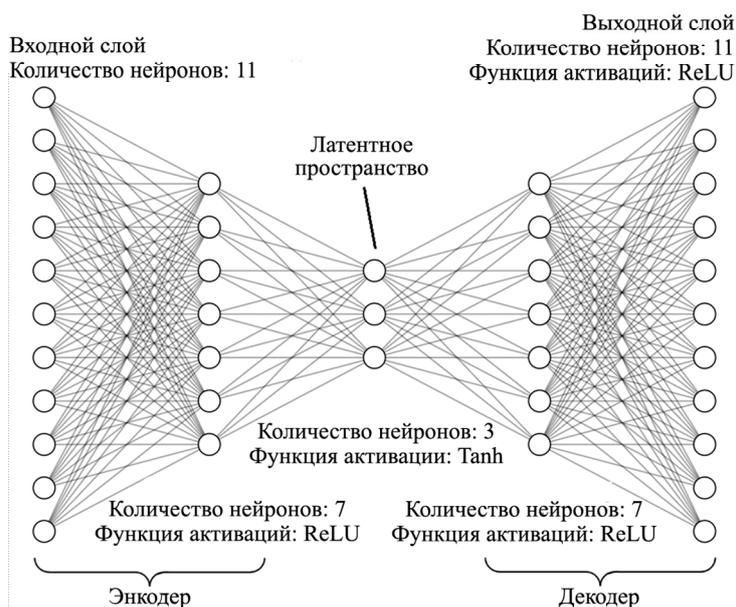


Рис. 2

Для настройки весовых коэффициентов нейронной сети применяется алгоритм Адам, эффективный в случае задач стохастической оптимизации [17]. Обучение нейронной сети на исследуемых данных занимает 750 эпох при 550 обучающих примерах в одной итерации. Предварительно все признаки нормируются на единичный интервал, что обеспечивает повышение сходимости процесса обучения нейронной сети и качества распознавания аномалий в работе электромеханического привода БЛА.

Ошибка реконструкции рассчитывается по формуле

$$L(X, \tilde{X}) = \sum_{k=1}^N |X_k - \tilde{X}_k|, \quad (2)$$

где X_k – признак с номером k ; N – количество признаков.

В качестве порогового значения ε , которое применяется для принятия решений о наличии аномалии с использованием формулы (1), был выбран максимум ошибки реконструкции на обучающей выборке, что обеспечивает высокую точность определения технического состояния электромеханического привода БЛА. Для рассматриваемой обучающей выборки $\varepsilon = 0,2117059$. В случае высокого уровня ложных тревог, генерируемых алгоритмом диагностики, ε может быть увеличено без переобучения нейронной сети.

Алгоритм диагностики электромеханического привода БЛА, созданный на основе модели обнаружения аномалий, был проверен на восьми тестовых (см. табл. 1). Для оценки качества разработанного алгоритма использовалась метрика Ассигасу – отношение количества правильно распознанных техниче-

ских состояний электромеханического привода БЛА к количеству применений модели обнаружения аномалий. Результаты расчетных исследований представлены в табл. 2.

Таблица 2

Выборка	Вязкое трение	Сухое трение	Люфт	Точность, %
Нормальный набор	0	0	0	100
Аномальный набор 1	0	0	1	100
Аномальный набор 2	0	1	0	94
Аномальный набор 3	0	1	1	100
Аномальный набор 4	1	0	0	74
Аномальный набор 5	1	0	1	100
Аномальный набор 6	1	1	0	92
Аномальный набор 7	1	1	1	100

Наблюдается закономерность: если неисправность распознается с высокой точностью хотя бы по одному параметру деградации, то наличие соответствующей ему неисправности одновременно с другими значительно снижает вероятность ошибки алгоритма диагностики. Модель обнаружения аномалий без ошибок определяет неисправность электромеханического привода БЛА по люфту на всех выборках. Когда наблюдается неисправность только по моменту сухого трения, неверно распознаются максимум 8 % выборки. Самое значительное количество ошибок алгоритмом диагностики допускается при распознавании неисправностей по вязкому трению (аномальный набор 4) – 26 % от выборки. Вместе с тем на нормальном наборе данных ошибок нет, т. е. случаи ложной тревоги отсутствуют. В целом точность работы алгоритма диагностики на тестовой выборке является высокой. Сформированное признаковое пространство и построенная модель обнаружения аномалий позволяет определить техническое состояние электромеханического привода БЛА с низким количеством ошибок.

Внедрение инновационных подходов к диагностике электромеханических агрегатов, применяемых в управлении полетом, является необходимым условием обеспечения конкурентоспособности и безопасности современных беспилотных авиационных систем. Результаты проведенных исследований показали, что полносвязная нейронная сеть типа «автокодировщик» может использоваться для создания алгоритмов диагностики электромеханического привода БЛА. Выбранная архитектура автокодировщика обеспечивает возможность автоматизированного оперативного обнаружения аномалий в работе электромеханического привода на основе нестационарных временных рядов, образованных значениями контролируемых параметров при выполнении маневра БЛА. По различным видам неисправностей и их сочетаниям в результате расчетных исследований показана высокая точность разработанного алгоритма диагностики. Подтверждена необходимость формирования признакового пространства, обеспечивающего повышение эффективности моделей обнаружения аномалий для широкого набора неисправностей электромеханического привода.

Полученные результаты предлагается использовать при создании перспективных обучающихся систем диагностики и в дальнейших исследованиях, направленных на повышение точности оценки технического состояния электромеханического привода БЛА.

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

СПИСОК ЛИТЕРАТУРЫ

1. Киселев М.А., Исмагилов Ф.Р., Саяхов И.Ф. Электроприводы управления аэродинамическими поверхностями летательных аппаратов // Вестник МАИ. 2017. № 2. С. 141–148.
2. Ismail M.A.A. et al. Design and Evaluation of Fault-Tolerant Electro-Mechanical Actuators for Flight Controls of Unmanned Aerial Vehicles // Actuators. 2021. Vol. 10. № 8. Article № 175.
3. Дородных Н.О. и др. О подходе к построению баз знаний для задач авиационной диагностики // Изв. вузов. Авиационная техника. 2025. № 1. С. 131–139.
4. Бельский А.Б., Есипович О.А., Сафоклов Б.Б. Экспериментальное апробирование применения искусственных нейронных сетей в системах диагностики для оценки и прогнозирования технического состояния агрегатов винтокрылых летательных аппаратов // Изв. вузов. Авиационная техника. 2024. № 1. С. 109–115.

5. Puchalski R., Giernacki W. UAV Fault Detection Methods, State-of-the-Art // Drones. 2022. Vol. 6. № 11. Article № 133.
6. Ekanayake T. et al. Model-Based Fault Diagnosis and Prognosis of Dynamic Systems: A Review // Procedia Manufacturing. 2019. Vol. 30. P. 435–442.
7. Neupane D. et al. Data-Driven Machinery Fault Diagnosis: A Comprehensive Review // Neurocomputing. 2025. Vol. 627. Article № 129588.
8. Narasimhan S. et al. Combining Model-Based and Feature-Driven Diagnosis Approaches – A Case Study on Electromechanical Actuators [Electronical Resource]. URL: <https://ntrs.nasa.gov/api/citations/20110008515/downloads/20110008515.pdf>. (дата обращения: 3.05.2025).
9. Benkuan Wang et al. Multivariate Regression Based Fault Detection and Recovery of UAV Flight Data // IEEE Transactions on Instrumentation and Measurement. 2019. Vol. 69. Iss. 6. P. 3527–3537.
10. D'Amato E. et al. A Particle Filtering Approach for Fault Detection and Isolation of UAV IMU Sensors: Design, Implementation and Sensitivity Analysis // Sensors. 2021. Vol. 21. № 9. Article № 3066.
11. Fourlas G.K., Karras G.C. A Survey on Fault Diagnosis and Fault-Tolerant Control Methods for Unmanned Aerial Vehicles // Machines. 2021. Vol. 9. № 9. Article № 197.
12. Ahmed Shoyeb Raihan, Imtiaz Ahmed. A Bi-LSTM Autoencoder Framework for Anomaly Detection – A Case Study of a Wind Power Dataset [Electronical Resource]. URL: <https://arxiv.org/pdf/2303.09703> (дата обращения: 3.05.2025).
13. Матренин П.В., Хальясмаа А.И., Потачиц Я.В. Автокодирующая рекуррентная нейронная сеть для задач автоматизации анализа временных рядов на объектах энергетики // Проблемы региональной энергетики. 2023. № 2. С. 61–71.
14. Jakovlev S., Voznak M. Auto-Encoder-Enabled Anomaly Detection in Acceleration Data: Use Case Study in Container Handling Operations // Machines. 2022. Vol. 10. № 9. Article № 734.
15. Румянцев Н.В., Соловьев С.В., Павлов Д.В. Интеллектуализированная система контроля, диагностики и прогнозирования состояния бортовых систем космических аппаратов // Тр. МАИ [Электронный журнал]. 2024. № 136. URL: <https://trudymai.ru/published.php?ID=180688&ysclid=mfmtn0yx5e571233184> (дата обращения: 3.05.2025).
16. Агафонов М.В. Применение интегрального исчисления в электротехнике [Электронный ресурс]. URL: <https://cyberleninka.ru/article/n/primenenie-integralnogo-ischisleniya-v-elektrotehnike> (дата обращения: 3.05.2025).
17. Kingma D.P., Ba J.L. Adam: A Method for Stochastic Optimization [Electronical Resource]. URL: <https://arxiv.org/pdf/1412.6980> (дата обращения: 3.05.2025).

Поступила в редакцию 3.06.25

После доработки 1.09.25

Принята к публикации 1.09.25

Algorithm for Diagnostics of an Aircraft Electromechanical Drive Using a Fully Connected Neural Network of the Autoencoder Type

G.S. VERESNIKOV¹, G.M. AVKHIMENKO¹, A.V. SKRYABIN¹, V.I. GONCHARENKO², YU.G. MIKHAILOV³, AND D.N. SOBOLEV¹

¹ ICS RAS, Moscow

² Moscow Aviation Institute (National Research University), Moscow

³ NRU MIET, Moscow

This paper proposes an algorithm for analyzing the technical condition of an electromechanical actuator deflecting the control surface of an unmanned aerial vehicle using machine learning models designed for anomaly detection. These models address the well-known novelty detection problem in observed data, which is interpreted as a fault in the monitored system. Computational experiments were conducted using data generated by simulating the actuator operation. Faults were considered. The procedure for splitting data into training and test sets is described. A fully connected neural network with an autoencoder architecture was selected to solve the anomaly detection problem. The paper discusses the extraction of diagnostic features and presents a methodology for deriving them from time series. The efficiency of the proposed diagnostic algorithm is estimated on various test sets, and the results are analyzed.

Anomaly detection, autoencoder, electromechanical actuator, technical condition diagnostics, neural network