

МАШИНОСТРОЕНИЕ И МАШИНОВЕДЕНИЕ

DOI: 10.34031/2071-7318-2025-10-12-110-123

^{1,*}Надежин М.И., ¹Слободзян Н.С., ²Жуков Ю.А.¹Центральный научно-исследовательский и опытно-конструкторский институт
робототехники и технической кибернетики²Балтийский государственный технический университет «ВОЕНМЕХ» им. Д.Ф. Устинова

*E-mail: mikhailn131@gmail.com

АЛГОРИТМ ВЫБОРА ПРИЗНАКОВ ДЛЯ ПОВЫШЕНИЯ ЭФФЕКТИВНОСТИ ДИАГНОСТИКИ ИСПОЛНИТЕЛЬНЫХ ЭЛЕМЕНТОВ КОСМИЧЕСКОЙ ТЕХНИКИ

Аннотация. Рассмотрены вопросы повышения точности и быстродействия работы алгоритмов диагностики технического состояния синхронного двигателя с постоянными магнитами методами машинного обучения. Разработан гибридный алгоритм выбора признаков, основанный на определении информативных признаков и удалении коррелирующих признаков, из исходной обучающей выборки. Для апробации предложенного алгоритма проведены экспериментальные исследования лабораторного образца синхронного двигателя с постоянными магнитами с нагрузкой в виде насосного агрегата и имитацией неисправностей статора. Исходная выборка состояла из временных, частотных и частотно-временных признаков сигналов фазных токов и параметров вибрации (виброускорений, виброскоростей и их огибающих) в общем количестве 158 штук. Применение алгоритма позволило сократить размер обучающей выборки до 6 признаков при увеличении точности и уменьшении времени диагностики. Также показано влияние неинформативных и коррелирующих между собой признаков на точность и быстродействие технической диагностики. Продемонстрировано на примере неисправностей электрического характера, что предложенный алгоритм может быть использован для определения наиболее чувствительных к изменению состояния двигателя измеряемых сигналов и выделяемых из них признаков, а также для локализации дефектов и идентификации неисправной фазы.

Ключевые слова: диагностика, электродвигатель, машинное обучение, выбор признаков, классификация.

Введение. Исполнительные элементы электромеханических систем космического назначения, таких как системы позиционирования, наведения и стабилизации навигационных объектов, манипуляционные системы обслуживания, электронасосные агрегаты систем терморегулирования, приводы мобильных колесно-шагающих роботов и других, являются автономными и, зачастую, необслуживаемыми агрегатами, к которым предъявляются высокие требования по безотказности и продолжительности работы.

В процессе эксплуатации электромеханических систем космического назначения уменьшается их ресурс, проявляются неисправности, критически изменяются их технические характеристики, что может приводить к выходу из строя системы в целом. Оценка состояния бортового оборудования путем диагностического контроля позволяет своевременно обнаружить тенденции развития отказов. Своевременное корректное определение технического состояния сложных электромеханических систем позволяет превентивно скорректировать их режим работы с целью увеличения срока службы и ресурса.

Современные подходы, например, на основе машинного обучения (МО) вследствие высокой точности и возможности выявления скрытых зависимостей получили широкое распространение

для решения задач технической диагностики электромеханических систем. Однако для успешной реализации большинство методов требует большого количества данных и высоких затрат вычислительных ресурсов, что является существенным ограничением для бортовых систем диагностики.

Разработка менее затратных по вычислительным ресурсам методов и алгоритмов диагностики электромеханических систем на базе МО позволит эффективно применять их во встраиваемых бортовых системах диагностики элементов космической техники.

В настоящей работе под словом признаки авторы подразумевают диагностические признаки, представляющие собой величины, отражающие изменения, которые происходят с измеряемыми параметрами в частотной или временной области. Примерами признаков могут быть среднеквадратичное значение, энергия спектра фазного тока и т.п. Измеряемые величины назовем диагностическими параметрами.

Применение методов МО характеризуется поэтапной работой с данными:

- получение исходных данных путем измерения датчиками или генерации моделями;
- разметка, нормирование и фильтрация исходных данных;

- выделение признаков;
- формирование обучающей выборки, состоящей из набора признаков, обеспечивающего наивысшее качество модели классификации. Здесь и далее под качеством модели классификации подразумевается точность и быстродействие;
- получение модели классификации для решения задачи диагностики.

Избыточность признаков при малом количестве наблюдений может привести к низкой точности диагностики. Наличие неинформативных и коррелирующих признаков в обучающей выборке вносит шумы и требует дополнительной обработки алгоритмами обучения.

Сокращенный набор данных сильнее коррелирует с выходными величинами, имеет меньший объем и требует меньшего количества вычислительных ресурсов, что играет ключевую роль при эффективном решении прикладных инженерных задач.

Диагностика электромеханического оборудования с помощью МО может быть реализована разными способами и подходами. Например, работы [1, 2] используют адаптивные состязательные сети для диагностики неисправностей механического, электрического и магнитного характера синхронного двигателя с постоянными магнитами (СДПМ). В исследовании [3] используют сверточные глубокие сети для диагностики подшипников по сигналам токопотребления инвертора и виброускорений корпуса двигателя. Авторы [4] анализируют изображения тепловизора с помощью нейронных сетей. В работе [5] обрабатывают временные параметры асинхронного электродвигателя с помощью самоорганизующихся нейронных сетей Кохонена. Исследование [6] демонстрирует определение межвитковых замыканий в фазах синхронного двигателя с помощью соревновательных сетей совместно с автоэнкодером.

В наземных применениях с производительными вычислительными устройствами наилучшие результаты показывают подходы на основе моделей глубокого обучения, например, с использованием сверточных нейронных сетей [1, 3], соревновательных сетей [1, 2, 6], глубоких автоэнкодеров [7, 8] и адаптационных сетей [9], однако они используют широкий набор исходных данных и имеют сложную архитектуру, что требует большого количества ресурсов вычислительного устройства и не применимо в бортовых системах.

Классические алгоритмы МО, например, метод ближайших соседей [10], метод опорных век-

торов [11, 12], наивный метод Байеса [11] или метод случайного леса [13] имеют более простую архитектуру и низкую размерность входных данных, что делает их фаворитами в бортовых системах технической диагностики. Одним из главных недостатков классических алгоритмов является необходимость получения корректного набора входных данных, т.е. диагностических признаков. Настоящая работа посвящена разработке алгоритма выделения признаков для формирования набора входных данных, решающего эту проблему.

Существует два основных подхода к сокращению обучающей выборки: выделение признаков и преобразование признаков. Алгоритмы выделения признаков позволяют выделить ограниченное количество признаков из исходного набора. Алгоритмы преобразования признаков позволяют трансформировать данные из исходного многомерного пространства объектов в новое пространство с уменьшенной размерностью.

Целью данной работы является разработка алгоритма выбора диагностических признаков, который позволит улучшить качество работы модели классификации, полученной методами машинного обучения, что повысит эффективность диагностики технического состояния электромеханических систем при задействовании меньшего количества диагностических параметров, уменьшении затрат памяти и вычислительных ресурсов.

Объектом исследования являются исполнительные элементы космической техники на основе СДПМ средней мощности (порядка 50–60 Вт), применяемых в составе бортовых систем различных устройств, в том числе в составе приводного двигателя для шарниров колесно-шагающих роботов вследствие их высокой энергоэффективности, длительного срока службы и подходящих характеристик. Исследуемая система состоит из электродвигателя с блоком управления и нагрузки в виде насосного агрегата.

Диагностика СДПМ методами МО заключается в решении задачи классификации, где каждый класс представляет собой техническое состояние: исправное или дефектное. Разные системы диагностики определяют разное количество состояний.

Материалы и методы. С целью получения статистических данных проведены экспериментальные исследования лабораторного образца СДПМ, аналогичного по характеристикам образцам, применяемым в составе колесно-шагающих роботов космического назначения (рис. 1). Номинальный режим работы обеспечивался с помощью нагрузки в виде насосного агрегата для создания плавного момента нагрузки.




Рис. 1. Лабораторный образец СДПМ

В рамках проведенного исследования рассматривались дефекты электрического характера, связанные со статором СДПМ.

Выполнялась имитация электрических неисправностей, по статистике [14,15] наиболее часто встречаемых на практике, что требует диагностического контроля.

Примем условные обозначения фаз: A , B , C .

Выполнена серия экспериментальных исследований работы двигателя в номинальном режиме нагрузки в следующих состояниях:

1. исправное состояние;
 - с увеличением сопротивления фазы B ;
 - с увеличением сопротивления фаз A , B , C ;
 - с наличием межвитковых замыканий в фазе A ;
 - с наличием межвитковых замыканий в фазах A и B ;
 - с обрывом фазы B .

Межвитковые замыкания и замыкания на общий провод в обмотках электрических машин вызывают ряд негативных эффектов [16]:

вибрации ротора, вызванные неравномерностью вращения вектора магнитного поля статора; появление паразитных токов, протекающих через подшипники скольжения, что снижает тем самым ресурс элементов конструкции и смазочных материалов;

возникновение дополнительных электрических потерь;

локальное возникновение зон перегрева;

перегрев закороченных витков, что может привести к пробое изоляции на общий провод.

В качестве диагностических параметров использовались сигналы токов фаз (условно: ia , ib , ic) и сигналы виброускорений (условно: gx , gy , gz) задней части корпуса двигателя: поперечное (X); вертикальное (Y); продольное (ось вращения вала – Z).

Аппаратная часть системы диагностики подробно описана в [17] и состоит из блока измерений диагностических параметров и анализатора спектра *ZETLAB*. Исходные массивы сохранялись через *SCADA*-систему *ZETVIEW*. Обработка данных, формирование моделей классификации и реализация алгоритмов выбора признаков происходила в пакете *MATLAB*®.

Основная часть. Авторы определяют классификацию алгоритмов выбора признаков следующим образом:

1. фильтры. Алгоритмы выбора признаков этого типа измеряют значимость признаков на основе характеристик, например, дисперсии. Выбор признаков в данном случае происходит как часть этапа предварительной обработки данных, после чего происходит обучение модели выбранными признаками. Такие алгоритмы выбора признаков не коррелируют с алгоритмом обучения;

2. обёртки. Алгоритм выбора признаков типа обёртки реализует обучение выборкой с подмножеством признаков с последующим добавлением или удалением нового признака из исходной выборки. Критерий выбора оценивает изменение производительности модели в результате добавления или удаления признака. Алгоритм изменяет выборку до тех пор, пока не будут выполнены критерии остановки;

3. алгоритмы встроенного типа. В таких алгоритмах выбор признаков является частью обучения;

4. гибридные алгоритмы – последовательное применение алгоритмов разного типа. Например, фильтрация признаков по статистическим свойствам и дальнейшее применение метода обёртки. Примеры таких методов представлены в работах [18,19].

Рассмотрены следующие алгоритмы выделения признаков:

- *One way ANOVA* – Однофакторный дисперсионный анализ [20] (фильтр);

- *Kruskal-Wallis* – Критерий Краскела-Уоллиса [21] (фильтр);

- *ChiSquare* – Критерий Хи-квадрат [22] (фильтр);

- *Minimum Redundancy Maximum Relevance (MRMR)* – минимальная избыточность максимальная релевантность [23] (обёртка);

- *Neighborhood component analysis (NCA)* – Компонентный анализ соседства [24] (фильтр, встроенный). Можно назвать встроенным, т.к. в процессе настройки оптимального параметра регуляризации используется обучение методом ближайших соседей;

- *ReliefF* [25] – адаптация алгоритма *Relief* (освобождения) к анализу многоклассовых данных (фильтр);

- корреляционный анализ (фильтр).

Главными требованиями к выделяемым из предобработанного массива данных признакам являются их корреляция с определяемым классом (неисправностью) и отсутствие корреляции признаков между собой. Алгоритмы выбора признаков позволяют реализовать указанные требования.

Авторами предлагается гибридный алгоритм выбора признаков. Принцип его работы представлен на рис. 2.



Рис. 2. Алгоритм работы гибридного метода выбора признаков

Каждый опыт сопровождался измерением диагностических параметров с частотой дискретизации 50 кГц отрезками продолжительностью 7 секунд в общем количестве 45. Конечное число опытов разбивалось в соотношении 2:1 на обучающие и тестовые данные соответственно.

Признаки, отображающие влияние дефектов на состояние электромеханической системы, в численном виде принято выделять из временной, частотной и, иногда, из частотно-временной

областей [26]. Признаки частотно-временной области определяются с помощью применения вейвлет-разложений исходных данных. Наиболее популярными и информативными признаками принято считать частотные признаки, чаще всего выражаемые в виде амплитуд всплесков на характерных частотах спектров измеряемых сигналов [17].

Исходный набор выделяемых признаков представлен в таблице 1. Подробные описания признаков можно найти в работе [26].

Таблица 1

Выделенные признаки, входящие в состав исходной выборки

Временная область:	Частотная область:
Среднеквадратичное значение (СКЗ)	Максимальное значение спектра
Куртозис	Энергия спектра
Клиренс фактор (КФ)	Спектральная плотность (<i>PSD</i>)
Пик-фактор (ПФ)	Пики на характерных частотах спектра
Форм-фактор (ФФ)	Частота вращения вала двигателя – 100 Гц (Пик 100)
Энтропия Шэннона (энтропия)	Вторая гармоника частоты вращения вала – 200 Гц (Пик 200)
Смещение	Частота вращения поля статора – 400 Гц (Пик 400)
Частотно-временная область:	Вторая гармоника частоты вращения поля статора – 800 Гц (Пик 800)
Коэффициент первого вейвлет-разложения (K1)	Частота коммутации обмоток – 1200 Гц (Пик 1200)
Коэффициент второго вейвлет-разложения (K2)	Четвертая гармоника частоты вращения поля статора – 1600 Гц (Пик 1600)
Коэффициента третьего вейвлет-разложения (K3)	Частота полюсных пульсаций тока – 2400 Гц (Пик 2400)
Коэффициента аппроксимации вейвлет-разложения (K аппроксим)	Вторая гармоника частоты полюсных пульсаций тока – 4800 Гц (Пик 4800)

Из данных каждого опыта для всех диагностических параметров выделялся набор из описанных выше признаков. Процесс повторялся для каждого исследования.

Завершающим этапом предобработки было нормирование данных по признакам алгоритмом минимакс [27].

Конечная выборка имела размер в 158 признаков для каждого проведенного экспериментального исследования.

Алгоритмы выбора ранжируют признаки путем расчета безразмерного параметра, характеризующего степень корреляции признака с определяемым классом. Определим этот параметр термином значимость.

Зачастую в своих работах исследователи используют один, максимум, два алгоритма, по

оценкам которых отбирают ограниченное количество признаков. Для повышения объективности оценки рассмотрим комплексный подход, заключающийся в совместном применении нескольких алгоритмов.

Различные алгоритмы дают результаты различного порядка. Например, критерий Хи-квадрат для наиболее значимого признака дает результат, равный бесконечности, а критерий Краскела-Уоллиса – сотни единиц. В связи с этим проводилось нормирование результатов каждого алгоритма по методу минимакс для их совместного применения.

Выполнена оценка значимости признаков. Результат для нескольких признаков представлен на рис. 3.




Рис. 3. Оценка значимости нескольких признаков из исходной выборки

Оценки всех алгоритмов по каждому признаку суммировались, давая совокупную оценку каждого признака. Для удобного представления результата конечная оценка также нормировалась методом минимакс, и полный

набор признаков ранжировался в соответствии с полученной оценкой значимости. Рассмотрим признаки с оценкой значимости более 0,7, которые представлены на рис. 4.

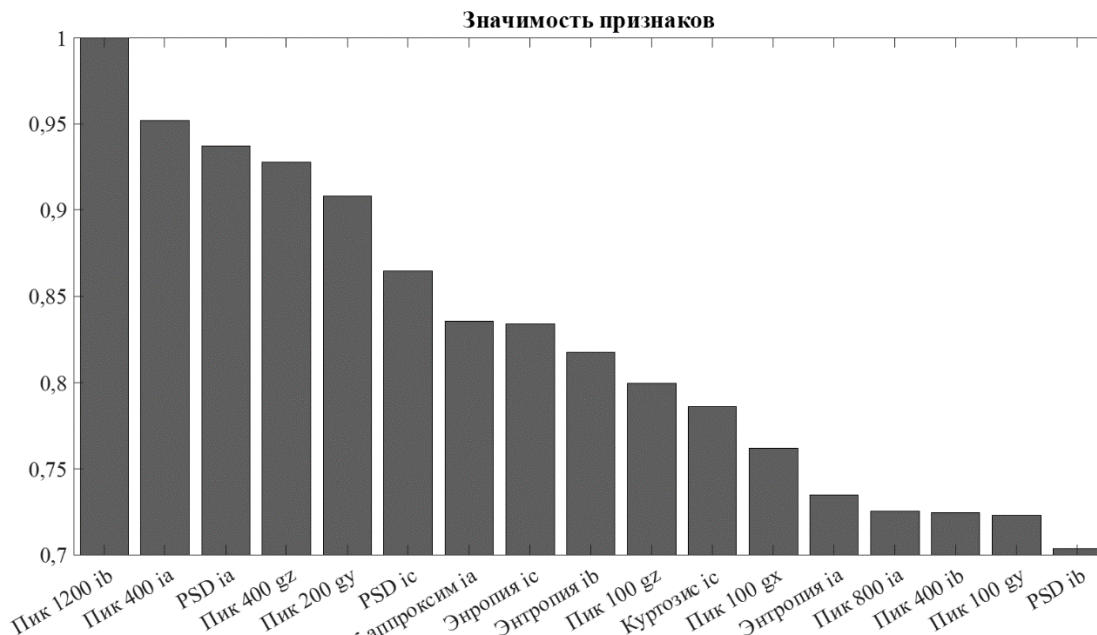


Рис. 4. Признаки с оценкой значимости выше 0,7

Для расчета коэффициентов корреляции между признаками был применен метод

Спирмена [28]. Коэффициенты корреляции первых пяти признаков представлены на рис. 5.

Коэффициенты корреляции					
куртозис ia	1	-0,2049	0,9356	-0,5868	0,9977
СКЗ ia	-0,2049	1	-0,1878	0,03527	-0,2212
ПФ ia	0,9356	-0,1878	1	-0,4841	0,917
КФ ia	-0,5868	0,03527	-0,4841	1	-0,6046
ФФ ia	0,9977	-0,2212	0,917	-0,6046	1
куртозис ia	СКЗ ia	ПФ ia	КФ ia	ФФ ia	

Рис. 5. Коэффициенты корреляции первых пяти признаков

В процессе работы алгоритма отбирались пары с коэффициентами корреляции выше граничного значения. Из коррелирующей пары исключался признак, оценка значимости которого ниже.

Далее из оставшегося набора исключались признаки с оценкой значимости ниже граничного значения.

Для определения граничных значений корреляции и значимости признаков, дающих

наилучшее качество диагностики, проводилось обучение и проверка качества моделей классификации при уровнях корреляции от 0,5 до 0,9 с шагом 0,1 и уровнях значимости от 0,3 до 0,8 с шагом 0,1.

Величина границы корреляции характеризует исключение признаков с коэффициентом корреляции выше граничного. Величина границы значимости характеризует исключение

признаков с уровнем значимости ниже граничного.

Применение одиночных алгоритмов выбора признаков или алгоритмов одного типа в задачах технической диагностики, например, только фильтров [29] или только оберток, не позволяет получить качественный результат, т.к. выделяемые признаки имеют сложные взаимосвязи друг с другом и с выходной характеристикой (состоянием исследуемой системы). Гибридные подходы показывают более эффективный результат, что будет показано в результатах настоящей работы.

Итерационный гибридный алгоритм в работе [30] использует жадный подход без учета корреляции признаков для решения задачи кластеризации. Подходы, основанные на глубоких нейронных сетях [31], требуют большого количества исходных данных и вычислительных ресурсов для выделения признаков, что сложно реализовать в задачах технической диагностики.

Новизна предлагаемого гибридного алгоритма заключается в комплексной оценке значимости признаков с помощью нескольких алгоритмов выбора признаков разного типа (фильтры, обертки и встроенный), при этом дополнительно используется корреляционный анализ для идентификации менее релевантных признаков, ориентируясь на комплексную оценку значимости. Предлагаемый итерационный подход с совместной взаимосвязанной оценкой значимости и корреляции признаков для сокращения обучающей выборки в задачах классификации и, в частности, в задаче технической диагностики электромеханических систем методами МО ранее не раскрывался.

С целью получения большей достоверности результатов проводилось обучение моделей классификации четырьмя методами МО, относящихся к разным семействам и основанных на отличающихся друг от друга принципах.

Рассматриваемые методы обучения:

- метод k -ближайших соседей (KNN);
- метод опорных векторов (SVM);
- метод деревьев;
- классификатор Байеса (метод Байеса).

Качество моделей классификации определялось двумя показателями: точность классификации (далее – точность) и время, затраченное на классификацию.

В таблице 2 представлены исходные показатели качества, полученные при работе с полным набором признаков.

На рис. 6 показан размер выборки для каждой пары границ корреляции и значимости. Минимальная граница значимости и максимальная

граница корреляции соответствуют минимуму отсекаемых признаков и наоборот.

Таблица 2

Исходные показатели качества моделей классификации

Метод	Точность	Время классификации, мс.
KNN	0,1429	9,7
SVM	0,1333	15,9
Метод деревьев	0,6857	7,1
Метод Байеса	0,1429	245,7




Рис. 6. Зависимость количества признаков от границ корреляции и значимости

На рис. 7 показаны результаты точности диагностики обученных разными методами МО моделей при всех комбинациях рассматриваемых границ корреляции и значимости. По оси абсцисс откладываются границы значимости, по оси ординат – точность. Разные уровни корреляции размечены линиями разного стиля.

Методы показывают низкую точность при малых границах корреляции. Это обусловлено большим количеством исключенных признаков – алгоритмам не хватает информации для точной работы.

Все рассматриваемые методы показывают высокую точность при границах корреляции 0,8 и 0,9, следовательно, корректной работе методов МО мешают только признаки с сильной корреляцией (0,8 и выше), а исключение признаков с более низкой корреляцией негативно сказывается на точности работы методов.

Все рассматриваемые методы имеют тенденцию к увеличению точности при отсеке наименее значимых признаков, что свидетельствует об эффективности применяемого алгоритма выбора признаков.

На рис. 8 аналогичным образом показаны результаты времени при всех комбинациях рассматриваемых границ корреляции и значимости.

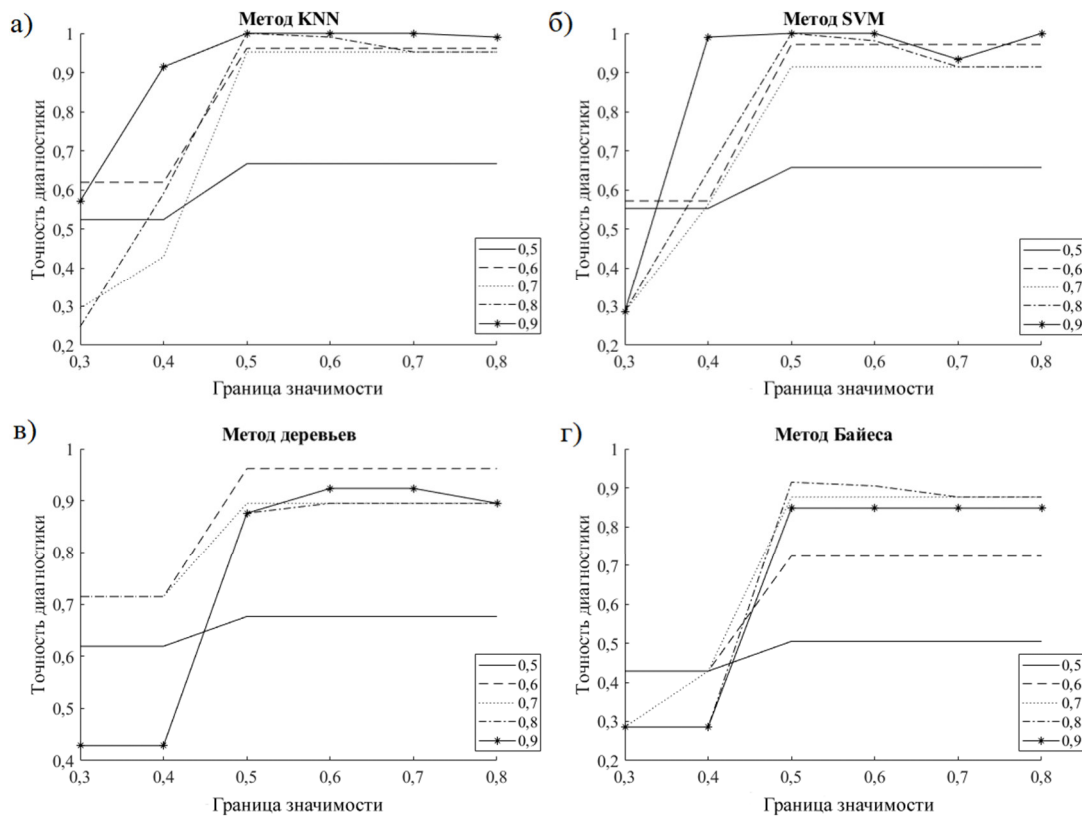


Рис. 7. Точность диагностики при различных границах корреляции и значимости
а) метод KNN, б) метод SVM, в) метод деревьев, г) метод Байеса

Теоретически, наименьшее время должно соответствовать высокой границе значимости и низкой границе корреляции вследствие наименьшего размера выборки, однако на практике зна-

чительное влияние вносит только отсечение признаков с низкой значимостью, в то время как отсечение большого количества коррелирующих признаков понижает время классификации только для классификатора Байеса.

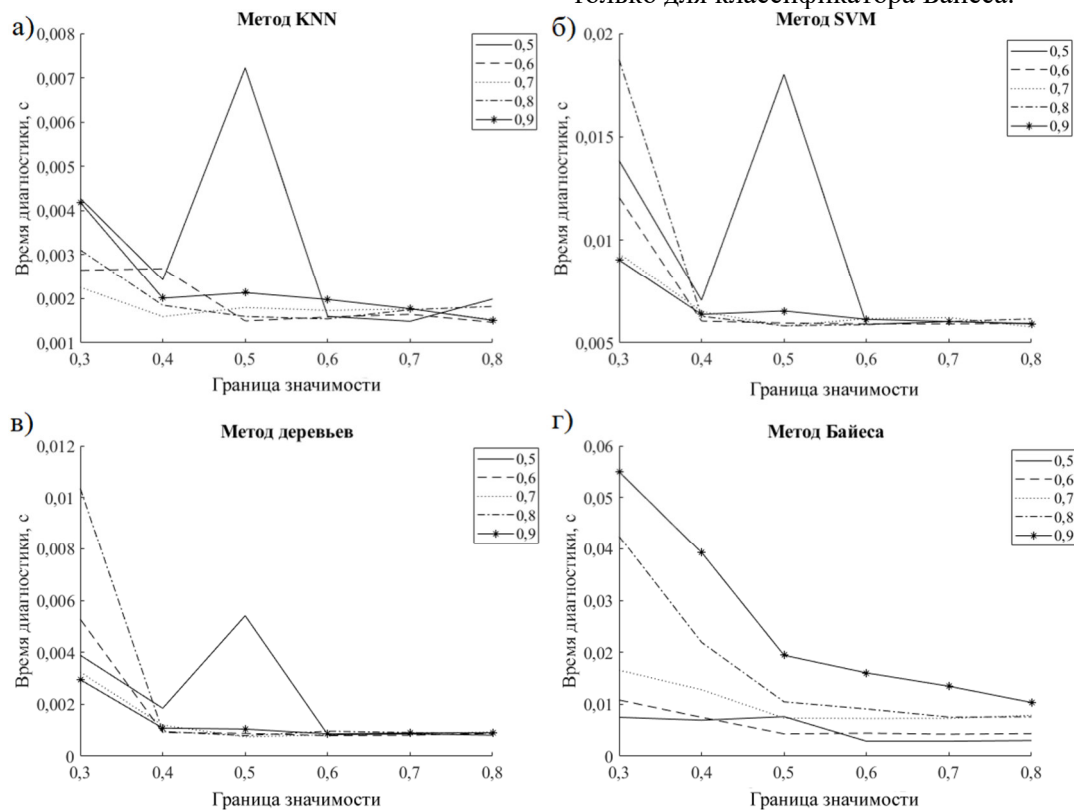


Рис. 8. Время диагностики при различных границах корреляции и значимости
а) KNN, б) SVM, в) деревьев, г) классификатор Байеса

Диагностика бортовых систем КА осуществляется в условиях аппаратных ограничений вычислительного устройства и средств телеметрии периодически с установленными временными промежутками без постоянного мониторинга. Отсюда следуют высокие требования к точности диагностики при минимизации используемой информации без жестких требований к быстродействию.

Среди рассматриваемых методов МО лучшую точность и время классификации при минимальном количестве диагностических параметров обеспечивает метод *KNN*, следовательно, он лучше остальных подходит для применения в бортовых системах диагностики.

На рис. 9 представлена зависимость показателей качества метода *KNN* от количества признаков в обучающей выборке.

Точность 100 % при быстродействии в 1,59 мс достигается с выборкой, состоящей из 6 признаков (признаки ранжированы по важности):

1. амплитуда всплеска частоты коммутации фаз спектра *ib*;
2. амплитуда всплеска на частоте вращения электромагнитного поля спектра *ia*;
3. спектральная плотность *ia*;

4. коэффициент аппроксимации *ia*;
5. КФ *ic*;
6. КФ *ia*.

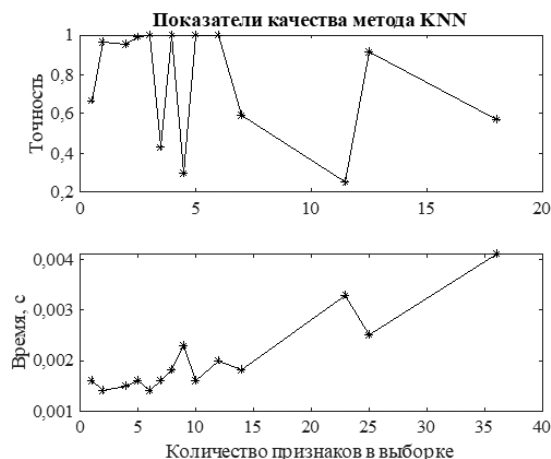


Рис. 9. Качество работы метода *KNN* в зависимости от количества признаков в обучающей выборке

Для сравнения качества работы предложенного алгоритма с описанными одиночными используемыми алгоритмами проведено их сравнение при классификации методом *KNN* в таблице 3.

Таблица 3

Качество работы моделей классификации, обученных методом *KNN*

Выборка	Точность классификации	Время классификации, мс	Количество признаков
Исходный набор	0,143	9,7	156
One-way ANOVA	0,285	3,9	2
Kruskal-Wallis	0,143	7,3	65
ChiSquare	0,143	5,4	29
MRMR	0,143	3,9	10
NCA	0,43	5,4	26
ReliefF	0,143	5,3	25
Корреляционный анализ с границей корреляции 0,8	0,365	4,7	18
Предложенный алгоритм	1	1,59	6

Полученная выборка отличается от предложенных в работах [10-13] вариативностью признаков из разных областей (как временной, так и частотной) при их меньшем количестве. Использование только спектральных признаков [10,11] будет недостаточным при низкой частоте дискретизации сигналов, что характерно для бортовых систем. Использование вейвлет-разложений [12,13] вычислительно сложнее и эффективно только при частых сменах режима работы исполнительных элементов.

В конечной выборке по количеству преобладают признаки сигналов фазных токов, в частности, токов фаз *A* и *B*. При этом в ходе экспери-

ментальных исследований большинство дефектов имитировалось в этих фазах. Следует вывод, что косвенным свойством предложенного алгоритма является определение наиболее информативных измеряемых сигналов и локализация дефекта рассматриваемой системы (в данном случае – идентификация неисправной фазы).

Стоит отметить, что амплитуда всплеска спектра виброускорения по продольной оси (*gz*) на частоте вращения электромагнитного поля и амплитуда всплеска спектра виброускорения по вертикальной оси (*gy*) на второй кратности частоты вращения вала заняли 4 и 5 места соответственно среди всех признаков по значимости

(рис. 4), однако были исключены в процессе работы алгоритма по причине корреляции с другими, более информативными, признаками. Из этого следует подтверждение корреляции электрических неисправностей с механическими характеристиками СДПМ, в частности, сильной корреляции продольных биений вала с сигналами фазных токов.

Результат подтверждает выводы общемировой практики о наибольшей значимости сигналов частотной области, в частности, амплитуд всплесков на характерных частотах рассматриваемой системы, в задачах диагностики технического состояния СДПМ. Признаки сигналов временной области менее значимы, однако необходимы для получения полноценной диагностической картины. Комбинирование частотных и временных сигналов способствует повышению эффективности диагностики.

Выводы.

Предложен гибридный алгоритм выделения признаков обучающей выборки для решения задачи диагностики технического состояния СДПМ.

Исключение коррелирующих признаков значительно улучшает точность и практически не влияет на быстродействие модели классификации. Исключение признаков с низкой значимостью повышает и точность, и быстродействие модели классификации.

Метод k -ближайших соседей продемонстрировал наилучшие показатели качества среди рассмотренных алгоритмов МО.

Предложенный алгоритм позволил сократить исходную выборку из 158 признаков до выборки из 6 признаков, полученных при использовании вдвое меньшего количества измеряемых величин и обеспечивающих стопроцентную точность диагностики неисправностей электрического характера в СДПМ. Несмотря на это, предложенный алгоритм склонен к переобучению, что демонстрируется стопроцентной точностью для ряда выборок, и требует в дальнейшем более тонкой настройки.

Эффективность работы алгоритма выбора ключевых признаков подтверждена для решения задачи технической диагностики и требует дальнейшей проверки для решения других задач классификации. Косвенными свойствами предложенного алгоритма являются определение наиболее информативных измеряемых сигналов и локализация дефекта рассматриваемой системы (в данном случае – идентификация неисправной фазы).

Благодарность. Данная работа выполнена в рамках НИР «Разработка и экспериментальные исследования алгоритмов автоматического управления движением колёсно-шагающего

шасси мобильного робота для передвижения в экстремальных напланетных условиях и при неопределённости характеристик подстилающей поверхности» (FNRG-2025-0018) 1024061000019-4-2.2.2 по государственному заданию № 075-00553-25-02 от 28.03.2025.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. Peng X., Peng T., Yang C., Ye C., Chen Z., Yang C. Adversarial domain adaptation network with MixMatch for incipient fault diagnosis of PMSM under multiple working conditions // Knowledge-Based Systems. 2024. Vol. 284. Pp. 111331. DOI: 10.1016/j.knosys.2023.111331
2. Ge Y., Zhang F., Ren Y. Adaptive fault diagnosis method for rotating machinery with unknown faults under multiple working conditions // Journal of Manufacturing Systems. 2022. Vol. 63. Pp. 177–184. DOI: 10.1016/j.jmsy.2022.03.009
3. Mueller P. N., Woelfl L., Can S. Bridging the gap between AI and the industry—A study on bearing fault detection in PMSM-driven systems using CNN and inverter measurement // Engineering Applications of Artificial Intelligence. 2023. T. 126. 06834. DOI: 10.1016/j.engappai.2023.106834
4. Glowacz A., Glowacz Z. Diagnostics of stator faults of the single-phase induction motor using thermal images, MoASoS and selected classifiers // Measurement. 2016. Vol. 93. Pp. 86–93. DOI: 10.1016/j.measurement.2016.07.008
5. Chuang C., Wei Z., Zhifu W., Zhi L. The Diagnosis Method of Stator Winding Faults in PMSMs Based on SOM Neural Networks // Energy Procedia. 2017. Vol. 105. Pp. 2295–2301. DOI: 10.1016/j.egypro.2017.03.663
6. Li Y., Wang Y., Zhang Y., Zhang J. Diagnosis of Inter-turn Short Circuit of Permanent Magnet Synchronous Motor Based on Deep learning and Small Fault Samples // Neurocomputing. 2021. Vol. 442. Pp. 348–358. DOI: 10.1016/j.neucom.2020.04.160
7. Jia F., Lei Y., Lin J., Zhou X., Lu N. Deep neural networks: A promising tool for fault characteristic mining and intelligent diagnosis of rotating machinery with massive data // Mechanical systems and signal processing. 2016. Vol. 72 Pp. 303–315. DOI: 10.1016/j.ymssp.2015.10.025
8. Chen Z., Guo R., Lin Z., Peng T., Peng X. A data-driven health monitoring method using multi-objective optimization and stacked autoencoder based health indicator // IEEE Transactions on Industrial Informatics. 2020. Vol. 17, No. 9. Pp. 6379–6389. DOI: 10.1109/TII.2020.2999323
9. Long M., Cao Y., Wang J., Jordan, M. Learning transferable features with deep adaptation net-

works // International conference on machine learning. PMLR. 2015. Pp. 97–105 DOI: 10.48550/arXiv.1502.02791

10. Ebrahimi B.M., Faiz J. Feature extraction for short-circuit fault detection in permanent-magnet synchronous motors using stator-current monitoring // IEEE Transactions on Power Electronics. 2010. Vol. 25, No. 10. Pp. 2673–2682 DOI: 10.1109/TPEL.2010.2050496

11. Pietrzak P., Wolkiewicz M. Machine learning-based stator current data-driven PMSM stator winding fault diagnosis // Sensors. 2022. Vol. 22, No. 24. 9668. DOI: 10.3390/s22249668

12. Muralidharan V., Sugumaran V., Indira V. Fault diagnosis of monoblock centrifugal pump using SVM // Engineering Science and Technology, an International Journal. 2014. Vol. 17, No. 3. Pp. 152–157. DOI: 10.1016/j.jestech.2014.04.005

13. Cerrada M., Zurita G., Cabrera D., Sánchez R. V., Artés M., Li C. Fault diagnosis in spur gears based on genetic algorithm and random forest // Mechanical Systems and Signal Processing. 2016. Vol. 70. Pp. 87–103. DOI: 10.1016/j.ymssp.2015.08.030

14. Geitner F.K., Bloch H.P. Machinery Failure Analysis and Troubleshooting (Fourth Edition) // Butterworth Heinemann. 2012. 743 p. DOI: 10.1016/C2010-0-67104-5

15. Orłowska-Kowalska T., Wolkiewicz M., Pietrzak P., Skowron M., Ewert P., Tarchala G., Kowalski C. T. Fault diagnosis and fault-tolerant control of PMSM drives—state of the art and future challenges // Ieee Access. 2022. Vol. 10. Pp. 59979–60024. DOI: 10.1109/ACCESS.2022.3180153

16. Матвеев С. А., Жуков Ю. А., Коротков Е. Б., Широбоков О. В., Надежин М. И., Ладыгин А. П. Обзор методов диагностики электронасосных агрегатов спутниковых платформ // Радиопромышленность. 2020. Т. 30, № 3. С. 86–98. DOI: 10.21778/2413-9599-2020-30-3-86-98

17. Коротков Е. Б., Слободзян Н. С., Широбоков О. В., Киселев А. А., Надежин М. И. Наземная система комплексной диагностики электро-механических устройств космических аппаратов // Радиопромышленность. 2019. Т. 29, № 4. С. 54–62. DOI: 10.21778/2413-9599-2019-29-4-54-62

18. Wei G., Zhao J., Feng Y., He A., Yu J. A novel hybrid feature selection method based on dynamic feature importance // Applied Soft Computing. 2020. Vol. 93. DOI: 10.1016/j.asoc.2020.106337

19. Chaudhuri A., Sahu T. P. A hybrid feature selection method based on Binary Jaya algorithm for micro-array data classification // Computers & Electrical Engineering. 2021. Vol. 90. DOI: 10.1016/J.COMPELECENG.2020.106963

20. Howell D. Statistical Methods for Psychology. Duxbury. 2002. Pp. 324–325

21. Kruskal W.H., Wallis W.A. Use of ranks in one-criterion variance analysis. // Journal of the American Statistical Association. 1952. Vol. 47, No. 260. Pp. 583–621

22. Vuong Q.H., Wang W. Minimum chi-square estimation and tests for model selection // Journal of Econometrics. 1993. Vol. 56. Pp. 141–168. DOI: 10.1016/0304-4076(93)90104-D

23. Ding C., Peng H. Minimum redundancy feature selection from microarray gene expression data. // Journal of Bioinformatics and Computational Biology. 2005. Vol. 3, No. 2. Pp. 185–205. DOI: 10.1109/CSB.2003.1227396

24. Yang, W., Wang K., Zuo W. Neighborhood Component Feature Selection for High-Dimensional Data // Journal of Computers. 2012. Vol. 7, No. 1. DOI: 10.4304/jcp.7.1.161-168

25. Robnik-Sikonja, M., Kononenko I. Theoretical and empirical analysis of ReliefF and RReliefF // Machine Learning. 2003. Pp. 23–69. DOI: 10.1023/A:1025667309714

26. Kimotho J.K., Sextro W. An approach for feature extraction and selection from non-trending data for machinery prognosis // European conference of the prognostics and health management society. 2014. DOI: 10.36001/phme.2014.v2i1.1462

27. Liu Z. A method of SVM with Normalization in Intrusion Detection // Procedia Environmental Sciences. 2011. Vol. 11. Pp. 256–262. DOI: 10.1016/j.proenv.2011.12.040

28. Gibbons J.D., Chakraborti S. Nonparametric statistical inference: revised and expanded. CRC press, 2014. 645 p.

29. Hopf K., Reifenrath S. Filter Methods for Feature Selection in Supervised Machine Learning Applications – Review and Benchmark // arXiv preprint arXiv:2111.12140. 2021. DOI: 10.48550/arXiv.2111.12140

30. Jashki M.A., Makki M., Bagheri E., Ghorbani A.A. An iterative hybrid filter-wrapper approach to feature selection for document clustering // Canadian Conference on Artificial Intelligence. – Berlin, Heidelberg: Springer Berlin Heidelberg. 2009. Pp. 74–85. DOI: 10.1007/978-3-642-01818-3_10

31. Li J., Cheng K., Wang S., Morstatter F., Trevino R. P., Tang J., Liu H. Feature selection: A data perspective // ACM computing surveys (CSUR). 2017. Vol. 50, No. 6. Pp. 1–45. DOI: 10.1145/3136625

Информация об авторах

Надежин Михаил Игоревич, начальник сектора «Проектирования мехатронных систем специального назначения». E-mail: mikhailn131@gmail.com. Центральный научно-исследовательский и опытно-конструкторский институт робототехники и технической кибернетики. Россия, Тихорецкий проспект, дом 21, г. Санкт-Петербург, 194064.

Слободзян Никита Сергеевич, кандидат технических наук, начальник отдела «Проектирования мехатронных систем». E-mail: ja-nikita@mail.ru. Центральный научно-исследовательский и опытно-конструкторский институт робототехники и технической кибернетики. Россия, Тихорецкий проспект, дом 21, г. Санкт-Петербург, 194064.

Жуков Юрий Александрович, старший преподаватель кафедры И8 «Системы приводов, мехатроника и робототехника». E-mail: zhkv@rambler.ru. Балтийский государственный технический университет «ВОЕНМЕХ» им. Д.Ф. Устинова. Россия, улица 1-я Красноармейская, дом 1, г. Санкт-Петербург, 190005.

Поступила 13.05.2025 г.

© Надежин М.И., Слободзян Н.С., Жуков Ю.А., 2025

^{1,*}Nadezhin M.I., ¹Slobodzyan N.S., ²Zhukov Yu.A.

¹Russian State Scientific Center for Robotics and Technical Cybernetics

²Baltic State Technical University "VOENMEH"

*E-mail: mikhailn131@gmail.com

FEATURE SELECTION ALGORITHM TO IMPROVE THE EFFICIENCY OF SPACE TECHNIC ELEMENTS DIAGNOSTICS

The issues of improving the accuracy and speed of algorithms for diagnosing the technical condition of a permanent magnet synchronous motor using machine learning methods are considered. A hybrid feature selection algorithm based on identifying informative features and removing correlating features from the original training sample has been developed. To test the proposed algorithm, experimental studies of a laboratory sample of a permanent magnet synchronous motor with a load in the form of a pumping unit and simulation of stator malfunctions were carried out. The initial sample consisted of 158 time, frequency, and time-frequency characteristics of phase current signals and vibration parameters (vibration accelerations, vibration velocities, and their envelopes). The use of the algorithm made it possible to reduce the size of the training sample to 6 features while increasing accuracy and reducing diagnostic time. The influence of uninformative and correlating features on the accuracy and speed of technical diagnostics is also shown. It is demonstrated by the example of electrical faults that the proposed algorithm can be used to determine the measured signals most sensitive to changes in the state of the motor and the signs isolated from them, as well as to localize defects and identify the faulty phase.

Keywords: diagnostics, electric drive, machine learning, feature selection, classification.

REFERENCES

1. Peng X., Peng T., Yang C., Ye C., Chen Z., Yang C. Adversarial domain adaptation network with MixMatch for incipient fault diagnosis of PMSM under multiple working conditions. Knowledge-Based Systems. 2024. Vol. 284. 111331. DOI: 10.1016/j.knosys.2023.111331
2. Ge Y., Zhang F., Ren Y. Adaptive fault diagnosis method for rotating machinery with unknown faults under multiple working conditions. Journal of Manufacturing Systems. 2022. Vol. 63. Pp. 177–184. DOI:10.1016/j.jmsy.2022.03.009
3. Mueller P.N., Woelfl L., Can S. Bridging the gap between AI and the industry—A study on bearing fault detection in PMSM-driven systems using CNN and inverter measurement. Engineering Applications of Artificial Intelligence. 2023. Vol. 126. 106834. DOI:10.1016/j.engappai.2023.106834
4. Glowacz A., Glowacz Z. Diagnostics of stator faults of the single-phase induction motor using thermal images, MoASoS and selected classifiers. Measurement. 2016. Vol. 93. Pp. 86–93. DOI:10.1016/j.measurement.2016.07.008
5. Chuang C., Wei Z., Zhifu W., Zhi L. The Diagnosis Method of Stator Winding Faults in PMSMs Based on SOM Neural Networks. Energy Procedia. 2017. Vol. 105. Pp. 2295–2301. DOI:10.1016/j.egypro.2017.03.663
6. Li Y., Wang Y., Zhang Y., Zhang J. Diagnosis of Inter-turn Short Circuit of Permanent Magnet Synchronous Motor Based on Deep learning and Small Fault Samples. Neurocomputing. 2021. Vol. 442. Pp. 348–358. DOI:10.1016/j.neucom.2020.04.160

7. Jia F., Lei Y., Lin J., Zhou X., Lu N. Deep neural networks: A promising tool for fault characteristic mining and intelligent diagnosis of rotating machinery with massive data. *Mechanical systems and signal processing*. 2016. Vol. 72. Pp. 303–315. DOI: 10.1016/j.ymssp.2015.10.025
8. Chen Z., Guo R., Lin Z., Peng T., Peng X. A data-driven health monitoring method using multiobjective optimization and stacked autoencoder based health indicator. *IEEE Transactions on Industrial Informatics*. 2020. Vol. 17, No. 9. Pp. 6379–6389. DOI: 10.1109/TII.2020.2999323
9. Long M., Cao Y., Wang J., Jordan, M. Learning transferable features with deep adaptation networks. *International conference on machine learning*. – PMLR. 2015. Pp. 97–105. DOI: 10.48550/arXiv.1502.02791
10. Ebrahimi B. M., Faiz J. Feature extraction for short-circuit fault detection in permanent-magnet synchronous motors using stator-current monitoring. *IEEE Transactions on Power Electronics*. 2010. Vol. 25, No. 10. Pp. 2673–2682. DOI: 10.1109/TPEL.2010.2050496
11. Pietrzak P., Wolkiewicz M. Machine learning-based stator current data-driven PMSM stator winding fault diagnosis. *Sensors*. 2022. Vol. 22, No. 24. 9668. DOI: 10.3390/s22249668
12. Muralidharan V., Sugumaran V., Indira V. Fault diagnosis of monoblock centrifugal pump using SVM. *Engineering Science and Technology, an International Journal*. 2014. Vol. 17, No. 3. Pp. 152–157. DOI: 10.1016/j.jestch.2014.04.005
13. Cerrada M., Zurita G., Cabrera D., Sánchez R. V., Artés M., Li C. Fault diagnosis in spur gears based on genetic algorithm and random forest. *Mechanical Systems and Signal Processing*. 2016. Vol. 70. Pp. 87–103. DOI: 10.1016/j.ymssp.2015.08.030
14. Geitner F.K., Bloch H.P. *Machinery Failure Analysis and Troubleshooting (Fourth Edition)*. Butterworth Heinemann. 2012. 743 p. DOI:10.1016/C2010-0-67104-5
15. Orlowska-Kowalska T., Wolkiewicz M., Pietrzak P., Skowron M., Ewert P., Tarchala G., Kowalski C.T. Fault diagnosis and fault-tolerant control of PMSM drives—state of the art and future challenges. *Ieee Access*. 2022. Vol. 10. Pp. 59979–60024. DOI:10.1109/ACCESS.2022.3180153
16. Matveev S.A., Zhukov Y.A., Korotkov E.B., Shirobokov O.V., Nadezhin M.I., Ladygin A.P. Overview of diagnostic methods for electric pump units of satellite platforms [Obzor metodov diagnostiki elektronasosnyh agregatov sputnikovyh platform]. *Radio industry*. 2020. Vol. 30. No. 3. Pp. 86–98. DOI:10.21778/2413-9599-2020-30-3-86-98 (rus)
17. Korotkov E.B., Slobodzyan N.S., Shirobokov O.V., Kiselev A.A., Nadezhin M.I. Spacecraft electromechanical devices' complex ground diagnostics system [Nazemnaya sistema kompleksnoj diagnostiki elektromekhanicheskikh ustroystv kosmicheskikh apparatov]. *Radio industry*. 2019. Vol. 29. No. 4. Pp. 54–62. DOI:10.21778/2413-9599-2019-29-4-54-62 (rus)
18. Wei G., Zhao J., Feng Y., He A., Yu J. A novel hybrid feature selection method based on dynamic feature importance. *Applied Soft Computing*. 2020. Vol. 93. DOI:10.1016/j.asoc.2020.106337
19. Chaudhuri A., Sahu T.P. A hybrid feature selection method based on Binary Jaya algorithm for micro-array data classification. *Computers & Electrical Engineering*. 2021. Vol. 90. DOI: 10.1016/J.COMPELECENG.2020.106963
20. Howell D. *Statistical Methods for Psychology*. Duxbury. 2002. Pp. 324–325
21. Kruskal W.H., Wallis W.A. Use of ranks in one-criterion variance analysis. *Journal of the American Statistical Association*. 1952. Vol. 47. No. 260. Pp. 583–621
22. Vuong Q.H., Wang W. Minimum chi-square estimation and tests for model selection. *Journal of Econometrics*. 1993. Vol. 56. Pp. 141–168. DOI: 10.1016/0304-4076(93)90104-D
23. Ding C., Peng H. Minimum redundancy feature selection from microarray gene expression data. *Journal of Bioinformatics and Computational Biology*. 2005. Vol. 3. No. 2. Pp. 185–205. DOI:10.1109/CSB.2003.1227396
24. Yang W., Wang K., Zuo W. Neighborhood Component Feature Selection for High-Dimensional Data. *Journal of Computers*. 2012. Vol. 7. No. 1. DOI:10.4304/jcp.7.1.161-168
25. Robnik-Sikonja M., Kononenko I. Theoretical and empirical analysis of ReliefF and RReliefF. *Machine Learning*. 2003. Pp. 23–69. DOI:10.1023/A:1025667309714
26. Kimotho J.K., Sextro W. An approach for feature extraction and selection from non-trending data for machinery prognosis. *European conference of the prognostics and health management society*. 2014. DOI: 10.36001/phme.2014.v2i1.1462
27. Liu Z. A method of SVM with Normalization in Intrusion Detection. *Procedia Environmental Sciences*. 2011. Vol. 11. Pp. 256–262. DOI:10.1016/j.proenv.2011.12.040
28. Gibbons J.D., Chakraborti S. *Nonparametric Statistical Inference*. CRC press, 2014. 645 p.
29. Hopf K., Reifenrath S. Filter Methods for Feature Selection in Supervised Machine Learning Applications—Review and Benchmark. *arXiv preprint arXiv:2111.12140*. 2021. DOI:10.48550/arXiv.2111.12140
30. Jashki M.A., Makki M., Bagheri E., Ghorbani A.A. An iterative hybrid filter-wrapper approach to feature selection for document clustering.

Canadian Conference on Artificial Intelligence. – Berlin, Heidelberg: Springer Berlin Heidelberg. 2009. Pp. 74–85. DOI: 10.1007/978-3-642-01818-3_10

31. Li J., Cheng K., Wang S., Morstatter F., Trevino R. P., Tang J., Liu H. Feature selection: A data perspective. ACM computing surveys (CSUR). 2017. Vol. 50, No. 6. Pp. 1–45. DOI: 10.1145/3136625

Information about the authors

Nadezhin, Mikhail I., head of sector. E-mail: mikhailn131@gmail.ru. Russian State Scientific Center for Robotics and Technical Cybernetics. Russia, 194064, Saint Petersburg, Tikhoretsky Prospect 21.

Slobodzyan, Nikita S., PhD, head of department. E-mail: ja-nikita@mail.ru. Russian State Scientific Center for Robotics and Technical Cybernetics. Russia, 194064, Saint Petersburg, Tikhoretsky Prospect 21.

Zhukov, Yuriy A., lead programmer. E-mail: zhkv@rambler.ru. Russian State Scientific Center for Robotics and Technical Cybernetics. Russia, 194064, Saint Petersburg, Tikhoretsky Prospect 21.

Received 13.05.2025

Для цитирования:

Надежин М.И., Слободзян Н.С., Жуков Ю.А. Алгоритм выбора признаков для повышения эффективности диагностики исполнительных элементов космической техники // Вестник БГТУ им. В.Г. Шухова. 2025. № 12. С. 110–123. DOI: 10.34031/2071-7318-2025-10-12-110-123

For citation:

Nadezhin M.I., Slobodzyan N.S., Zhukov Yu.A. Feature selection algorithm to improve the efficiency of space technic elements diagnostics. Bulletin of BSTU named after V.G. Shukhov. 2025. No. 12. Pp. 110–123. DOI: 10.34031/2071-7318-2025-10-12-110-123