

Рубрика 2. НАУЧНЫЕ И ПРАКТИЧЕСКИЕ РАЗРАБОТКИ

Направление – Электротехнические комплексы и системы

<https://doi.org/10.17816/transsyst682000>

Труды III конференции с международным участием «Проблемы безопасности и эффективности технических систем», посвященной 205-й годовщине начала научно-педагогической деятельности Бенуа Поля Эмиля Клапейрона в Институте Корпуса инженеров путей сообщения

© Е.Г. Серeda¹, А.С. Соловьев^{2, 3}

¹ ООО «Рэкфорк»

² Петербургский государственный университет путей сообщения
Императора Александра I

³ АО «Силовые машины»
(Санкт-Петербург, Россия)

ОПРЕДЕЛЕНИЕ НЕИСПРАВНОСТЕЙ АСИНХРОННЫХ ДВИГАТЕЛЕЙ С ПОМОЩЬЮ АЛГОРИТМОВ МАШИННОГО ОБУЧЕНИЯ

Обоснование. Методы машинного обучения представляют собой современное и эффективное средство обеспечения функционирования различных технических систем, в том числе систем диагностирования. По мере накопления статистических данных о неисправностях диагностические системы, построенные на алгоритмах машинного обучения, обеспечивают более высокую точность прогнозирования и при этом не требуют дорогостоящего диагностического оборудования и высокой квалификации персонала.

Цель. Разработка диагностической системы, способной не только определять наличие неисправности, но и с высокой точностью оценивать степень ее развития.

Материалы и методы. Объектом исследования является трехфазный асинхронный двигатель с короткозамкнутым ротором; для достижения поставленной цели используются методы машинного обучения.

Результаты. На примере межвиткового короткого замыкания в обмотке статора показана возможность определения неисправности и степени ее развития даже на начальном этапе (при малом числе короткозамкнутых витков) с точностью не менее 95%.

Закключение. Методы машинного обучения позволяют создавать эффективные и недорогие диагностические системы, отличающиеся универсальностью, высокой точностью и не требующие высококвалифицированного персонала.

Ключевые слова: диагностика; машинное обучение; асинхронный двигатель; межвитковое замыкание обмотки.

Как цитировать:

Серeda Е.Г., Соловьев А.С. Определение неисправностей асинхронных двигателей с помощью алгоритмов машинного обучения // Инновационные транспортные системы и технологии. 2025. Т. 11, № 2. С. 261–272. doi: 10.17816/transsyst682000

Section 2. SCIENTIFIC AND PRACTICAL DEVELOPMENTS

Subject – Electrotechnical complexes and systems

© E.G. Sereda¹, A.S. Solovyov^{2, 3}¹ LLC “RackFork”² Emperor Alexander I St. Petersburg State Transport University³ JSC “Power machines”

(St. Petersburg, Russia)

ASYNCHRONOUS MOTOR FAULT DETECTION USING MACHINE LEARNING ALGORITHMS

BACKGROUND. Machine learning methods are effective advanced means ensuring the operability of various engineering systems, including test systems. As statistics on faults accumulate, test systems based on machine learning algorithms provide higher prediction accuracy and do not require expensive test equipment and skilled personnel.

AIM. To develop a test system capable of both determining the fault and assessing its extent with high accuracy.

MATERIALS AND METHODS. The subject of the study is a three-phase asynchronous motor with a squirrel cage rotor; machine learning methods are used to achieve the goal.

RESULTS. Using the example of interturn faults in the stator winding, the authors demonstrate that it is possible to detect the fault and its extent even at the initial stage (with a few short-circuited turns) with an accuracy of at least 95%.

CONCLUSION. Machine learning methods allow to develop effective and affordable test systems that are versatile, highly accurate, and do not require skilled personnel.

Keywords: testing; machine learning; asynchronous motor; interturn winding fault.

To cite this paper:

Sereda EG, Solovyov AS. Asynchronous Motor Fault Detection Using Machine Learning Algorithms. *Modern Transportation Systems and Technologies*. 2025;11(2):261–272. doi: 10.17816/transsyst682000

ВВЕДЕНИЕ

Асинхронные двигатели получили широкое распространение в электроприводе транспортных средств и технологических механизмов предприятий промышленности и транспорта благодаря простоте конструкции, надежности в эксплуатации и ремонтпригодности. По данным статистики асинхронные двигатели потребляют до 80% электрической энергии в промышленности и до 30% на транспорте. Несмотря на высокую надежность, асинхронные двигатели подвержены отказам, наиболее частыми причинами которых являются эксплуатационные перегрузки (около 50% случаев) и технологические нарушения (около 35% случаев). Для асинхронных двигателей общепромышленного исполнения мощностью 5 кВт и выше около 85% отказов происходят из-за повреждения обмоток статора, при этом свыше 90% от этого числа составляют межвитковые замыкания. Для асинхронных двигателей, работающих в особо тяжелых условиях эксплуатации, связанных с тепловыми, вибрационными и ударными механическими нагрузками, в частности тяговых двигателей, распределение отказов по элементам конструкции может отличаться от приведенных значений в сторону увеличения процента отказов подшипниковых узлов и обрыва стержней ротора [1–4].

Контроль технического состояния и диагностирование неисправностей являются важным элементом правильной эксплуатации электрических машин и эффективным инструментом предупреждения отказов, вызывающих нарушение технологического процесса. В настоящее время известно множество методов диагностирования неисправностей электрических машин, однако большинство из них связано с необходимостью остановки двигателя и технологического механизма. Кроме того, многие методы для правильной интерпретации результатов диагностики требуют участия высоко квалифицированного персонала [5–9]. По этим причинам в последнее время возрастает интерес к системам диагностирования, основанным на методах машинного обучения при минимальном участии обслуживающего персонала и минимальной потребности в измерительном оборудовании [10, 11].

ПОСТАНОВКА ЗАДАЧИ. МОДЕЛЬ МАШИННОГО ОБУЧЕНИЯ

В настоящей работе рассматривается следующая задача: для асинхронного трехфазного двигателя на основе методов машинного

обучения создать систему диагностирования, способную малыми измерительными средствами с достаточной точностью определять не только наличие неисправности, но и степень ее развития. В качестве неисправности, идентификация которой осуществляется методами машинного обучения, выступает наиболее распространенная причина отказов асинхронных двигателей – межвитковое короткое замыкание обмотки статора.

Модель машинного обучения, способная анализировать и диагностировать неисправности асинхронных двигателей, создана на базе экспериментального стенда, схема которого представлена на Рис. 1. Две фазы асинхронного двигателя АД питаются от преобразователя частоты ПЧ через автотрансформатор АТ, третья фаза АД питается от ПЧ напрямую. Таким образом удастся имитировать межвитковое короткое замыкание в третьей фазе двигателя. Путем изменения положения подвижного контакта АТ можно также имитировать межвитковое короткое замыкание различного количества витков в фазе обмотки статора АД. Два датчика тока ДТ передают сигнал на измерительное устройство ИУ, связанное с персональным компьютером ПК. Нагрузка АД обеспечивается




Рис. 1. Экспериментальный стенд

ПЧ – преобразователь частоты; АТ – автотрансформатор; ДТ1, ДТ2 – датчики тока;
АД – асинхронный двигатель; МПТ – машина постоянного тока; ОВ – обмотка независимого возбуждения МПТ; СУ МПТ – система управления МПТ;
ИУ – измерительное устройство; ПК – персональный компьютер.

Fig. 1. Experimental setup

ПЧ – frequency converter; АТ – autotransformer; ДТ1, ДТ2 – current sensors;
АД – asynchronous motor; МПТ – direct current machine; ОВ – independent excitation winding of МПТ; СУ МПТ – control system of МПТ; ИУ – measuring device;
ПК – personal computer.

машиной постоянного тока МПТ независимого возбуждения, создающей противодействующий момент на валу двигателя АД. В Табл. 1 представлен объем собранных экспериментальных данных для различного количества короткозамкнутых витков фазы обмотки статора АД. Исходный сигнал, получаемый от датчиков тока ДТ, представлен на Рис. 2.

Корректное применение алгоритмов машинного обучения возможно лишь после обработки (фильтрации) сигналов, получаемых от датчиков тока ДТ. Такая фильтрация сигналов, содержащих высокочастотные помехи, осуществлена с помощью фильтра на базе операционного усилителя LM252 и алгоритмически на основе скользящего среднего (Рис. 3). Обработанные, без помех сигналы датчиков ДТ1 и ДТ2 далее были нормализованы и приведены к одинаковой размерности с числом периодов $N=4$.

Таблица 1. Объем собранных экспериментальных данных для обучения модели

Table 1. Volume of collected experimental data for model training

Наличие межвиткового короткого замыкания	Количество измерений
Без межвиткового короткого замыкания	142
Межвитковое короткое замыкание, 5 % числа витков	85
Межвитковое короткое замыкание, 10 % числа витков	80
Межвитковое короткое замыкание, 15 % числа витков	90




Рис. 2. Исходный сигнал, получаемый от датчиков тока ДТ

Fig. 2. Initial signal received from the DT current sensors

На Рис. 4 представлены обработанные и нормализованные сигналы датчиков тока для двух различных степеней развития межвиткового короткого замыкания в фазе обмотки статора АД. Видно, что сигналы для этих случаев визуально практически неотличимы, что делает применение стандартных методов диагностирования малоэффективным и приводит к необходимости использовать методы машинного обучения, позволяющие с достаточной точностью определить, как вид неисправности, так и степень ее развития [12].




Рис. 3. Сигнал датчиков тока ДТ1, ДТ2 после фильтрации высокочастотных помех

Fig. 3. Signal from current sensors after filtering high-frequency interference




Рис. 4. Вид нормализованных сигналов датчиков тока после фильтрации для различной степени развития межвиткового короткого замыкания:
a – короткое замыкание 5% витков; *b* – короткое замыкания 15% витков

Fig. 4. View of normalized signals from current sensors after filtering for different degrees of development of interturn short circuit:
a – short circuit of 5% of turns; *b* – short circuit of 15% of turns

НЕКОТОРЫЕ МЕТОДЫ МАШИННОГО ОБУЧЕНИЯ ДЛЯ РЕШЕНИЯ ПОСТАВЛЕННОЙ ЗАДАЧИ

Рассмотрим несколько методов машинного обучения, которые могут быть использованы при решении поставленной задачи.

Метод случайного леса (Random Forest) представляет собой метод, используемый для решения задач классификации и регрессии, и основан на объединении множества деревьев решений для улучшения точности и устойчивости модели. Алгоритм метода заключается в создании множества деревьев решений и использовании их для поиска окончательного решения. Каждое из деревьев строится на случайном подмножестве обучающих данных и признаков, в результате чего деревья отличаются друг от друга, что позволяет уменьшить эффект переобучения и повысить качество предлагаемых решений. Этот метод обеспечивает высокую точность, устойчивость к переобучению за счет использования подвыборок и случайных признаков, характеризуется большей гибкостью в силу того, что может обрабатывать пропущенные данные, и позволяет определить, какие признаки оказывают наиболее сильное влияние на результат. К недостаткам метода можно отнести потребность в настройке сложных параметров и необходимость значительного времени для обучения модели, особенно при использовании большого количества деревьев решений [13].

Метод Extreme Gradient Boosting обеспечивает высокую точность и масштабируемость результатов. Модели, которые обычно представляют собой деревья решений, обучаются последовательно, при этом последующая модель исправляет ошибки предыдущих. Первым этапом алгоритма является обучение базовой модели, которая в задачах регрессии прогнозирует среднее значение целевой переменной, и вычисление ошибок между прогнозируемыми и фактическими значениями. Обучение следующего дерева осуществляется на ошибках предыдущего с исправлением этих ошибок, далее процесс повторяется до тех пор, пока не будет удовлетворен критерий остановки. Преимуществами метода являются возможность параллельных вычислений, устойчивость к переобучению и выбросам, высокая точность, работа с пропущенными значениями, возможность обрабатывать новые данные. К недостаткам можно отнести трудоемкость вычислений, особенно при обучении сложных моделей, что затрудняет использование этого метода для систем с ограниченными ресурсами [14].

Метод логистической регрессии (Logistic Regression) используется для разделения данных на классы и моделирования вероятности отнесения

данных к одному из классов. Суть метода заключается в прогнозировании вероятности возникновения некоторого события на основе данных об уже случившихся событиях. В отличие от обычной регрессии метод не предполагает прогнозирования численного значения переменной, а определяет вероятность того, что исходное значение будет принадлежать к определенному классу. Преимущества метода заключается в простоте реализации и интерпретации данных, удобстве использования для начальных этапов анализа данных, способности к быстрому обучению, возможности интерпретировать коэффициенты модели как показатели важности признака. Недостатками являются невозможность решения нелинейных задач, чувствительность к шуму и выбросам (аномальные значения могут существенно повлиять на результат), при наличии сильно взаимосвязанных переменных коэффициенты могут стать нестабильными и сложно интерпретируемыми [15, 16]. Логистическая регрессия изначально предназначена для бинарной классификации, но её можно адаптировать для задач с несколькими классами (мультиклассовая классификация). Одним из подходов является: One-vs-Rest (OvR) / One-vs-All (OvA). Этот подход основан на том, что для каждого класса создаётся отдельная бинарная модель, которая предсказывает вероятность принадлежности к этому классу против всех остальных. На этапе предсказания выбирается класс с наибольшей вероятностью.

РЕЗУЛЬТАТЫ

Методы случайного леса, Extreme Gradient Boosting и логической регрессии использованы для решения поставленной задачи по определению наличия межвиткового замыкания в фазе обмотки статора АД и степени его развития. Сравнение точности указанных алгоритмов машинного обучения для решения задачи проводилось при помощи перекрестной проверки при разделении данных на десять частей. Результаты представлены в Табл. 2.

Таблица 2. Точность использованных методов машинного обучения

Table 2. Accuracy of the machine learning methods used

Алгоритм	Точность	Отклонение
Метод случайного леса (Random Forest)	0,931	0,079
Метод экстремального усиления градиента (EG Boosting)	0,937	0,054
Метод логической регрессии (Logistic Regression)	0,985	0,020

Для решения поставленной задачи наиболее точным оказался метод логистической регрессии (точность 98,5%). ROC кривые (Receiver Operating Characteristics), которые показывают насколько хорошо модель машинного обучения может различать два класса событий, а также матрица ошибок, показывающая количество правильных и ошибочных предсказаний для каждого класса при обучении модели на 60% собранных данных, представлены на Рис. 5.




Рис. 5. Матрица ошибок (слева) и ROC кривая (справа)
для алгоритма логистической регрессии

Fig. 5. Error matrix (left) and ROC curve (right) for the logistical regression algorithm

ЗАКЛЮЧЕНИЕ

На примере межвиткового короткого замыкания обмотки статора асинхронного двигателя показано, что алгоритмы машинного обучения являются эффективным средством диагностики не только наличия неисправности, но и позволяют с достаточной точностью определять степень ее развития. Используемые в работе методы позволяют с высокой достоверностью определять наличие межвиткового короткого замыкания даже при весьма малом числе короткозамкнутых витков обмотки, что дает возможность диагностировать неисправность на начальном этапе ее развития и предупредить нарушение технологического процесса. Диагностика с помощью методов машинного обучения характеризуется низкой стоимостью измерительно-диагностического оборудования и не требует специальных навыков обслуживающего персонала. Методы

машинного обучения могут быть использованы для диагностики неисправностей различных элементов конструкции электрических машин; точность диагностирования будет при этом увеличиваться по мере накопления статистических данных.

Авторы заявляют что:

1. У них нет конфликта интересов;
2. Настоящая статья не содержит каких-либо исследований с участием людей в качестве объектов исследований.

The authors state that:

1. They have no conflict of interest;
2. This article does not contain any studies involving human subjects.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. Котеленец Н.Ф., Акимова Н.А., Антонов М.В. Испытания, эксплуатация и ремонт электрических машин. М.: Академия, 2003.
2. Дорохина Е.С., Голдовская А.А., Гирник А.С. Прогнозирование остаточного ресурса асинхронных электродвигателей // Проблемы машиностроения и надежности машин. 2019. № 4. С. 63-67.
3. Воробьев В.Е., Кучер В.Я. Прогнозирование срока службы электрических машин. СПб: СЗТУ, 2004.
4. Рыжова Е.Л., Ким К.К., Иванов С.Н. Оценка надежности тяговых двигателей на основе состояния электрической изоляции обмотки // Ученые записки Комсомольского-на-Амуре государственного технического университета. 2023. № 5 (69). С. 8-14.
5. Мясоедова М.А., Мамонова Л.Г. Анализ современных методов диагностики электрооборудования. В кн.: Технологии, машины и оборудование для агропромышленного комплекса: сборник научных статей 2-й Всероссийской научно-технической конференции, Курск, 05 июня 2024 года. Курск: Университетская книга, 2024. С. 81-84.
6. Королева Е.Б., Курмашев С.М., Ким К.К., и др. Устройства экспресс-диагностирования силовых полупроводниковых приборов и полупроводниковых преобразователей // Омский научный вестник. 2023. № 2 (186). С. 119-125.
7. Siddique A., Yadava G., Singh B. A Review of Stator Fault Monitoring Techniques of Induction Motors // IEEE transactions on energy conversion. 2005. Vol. 20, N. 1. P. 106-114. doi: 10.1109/TEC.2004.837304
8. Villada F., Cadavid D., Munoz N., et al. Fault Diagnosis in Induction Motors Fed by PWM Inverters. In: 4th IEEE International Symposium on Diagnostics for Electric Machines, Power Electronics and Drives, 2003. SDEMPED, 2003. P. 229-234. doi: 10.1109/DEMPED.2003.1234578
9. Рыжова Е.Л., Осипов В.Ю. Применение технических средств диагностирования тяговых двигателей подвижного состава // Инновационные транспортные системы и технологии. 2024. Т. 10, № 4. С. 556-576. EDN: GOMQNE doi: 10.17816/transsyst635142

10. Сальников С.В., Солодкий Е.М., Вишняков Д.Д., и др. Диагностика асинхронного двигателя на основе машинного обучения. В кн.: XXVI Международная конференция по мягким вычислениям и измерениям (SCM-2023). Сборник докладов. Санкт-Петербург, 24–26 мая 2023 г. СПб: СПбГЭТУ «ЛЭТИ», 2023. С. 295-300. EDN: BXTXDQ
11. Хальясмаа А.И. Машинное обучение как инструмент повышения эффективности управления жизненным циклом высоковольтного электрооборудования // Вестник Иркутского государственного технического университета. 2020. Т. 246. № 5. С. 1093-1104.
12. Коробейников А.Б., Сарваров А.С. Анализ существующих методов диагностирования электродвигателей и перспективы их развития // Электротехнические системы и комплексы 2015. №1 (26). С. 4-9.
13. Breiman L. Random Forests // Machine Learning. 2001. Vol. 45, N. 1. P. 5-32. doi: 10.1023/A:1010933404324
14. Chen T, Guestrin C. XGBoost: A Scalable Tree Boosting System. In: Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. San Francisco: ACM, 2016. P. 785-794.
15. Флах П. Машинное обучение. Наука и искусство построения алгоритмов, которые извлекают знания из данных. М.: ДМК Пресс, 2015.
16. Кугаевских А.В., Муромцев Д.И., Кирсанова О.В. Классические методы машинного обучения. СПб: Университет ИТМО, 2022.

REFERENCES

1. Kotelents NF, Akimova NA, Antonov MV. *Ispytania, ekspluatatsia i remont elektricheskikh mashin*. Moscow: Akademia; 2003. (In Russ.)
2. Dorokhina ES, Goldovskaya AA, Girnik AS. A Way To Predict The Residual Lifetime Of Induction Traction Electric Motors. *Journal of Machinery Manufacture and Reliability*. 2019;48(4):336-339. (Russ., Engl.) doi: 10.1134/S0235711919040060
3. Vorobiev VE, Kucher VIa. *Prognozirovanie sroka sluzhby elektricheskikh mashin*. St.-Petersburg: SZTU, 2004. 56 p. (In Russ.).
4. Ryzhova EL, Kim KK, Ivanov SN. Evaluation of Traction Motor Reliability Based On The State Of Winding Electrical Insulation. *Uchenye zapiski Komsomol'skogo-na-Amure gosudarstvennogo tehničeskogo universiteta*. 2023; 5(69):8-14. (In Russ.). doi: 10.17084/20764359-2023-69-8
5. Miasoedova MA, Mamonova LG. Analiz sovremennykh metodov diagnostiki elektrooborudovania. In: *Proceedings of the 2nd All-Russian Scientific and Practical Conference "Technologii, mashiny i oborudovanie dlya agropromyshlennogo kompleksa"*. 2024 June 5. Kursk: Universitetskaya Kniga. 2024:81-84. (In Russ.).
6. Koroleva EB, Kurmashev SM, Kim KK, Tkachuk AA, Kuznetsov AA. Devices for express diagnostics of power semiconductor devices and semiconductor converters. *Omsk Scientific Bulletin*. 2023;2(186):119-125. (Russ., Engl.) doi: 10.25206/1813-8225-2023-186-119-125

7. Siddique A, Yadava G, Singh B. A Review of Stator Fault Monitoring Techniques of Induction Motors. *IEEE transactions on energy conversion*. 2005;20(1):106-114. doi: 10.1109/TEC.2004.837304
8. Villada F, Cadavid D, Munoz N, et al. Fault Diagnosis in Induction Motors Fed by PWM Inverters. In: *4th IEEE International Symposium on Diagnostics for Electric Machines, Power Electronics and Drives, 2003*. SDEMPED; 2003:229-234. doi: 10.1109/DEMPED.2003.1234578
9. Ryzhova EL, Osipov VYu. The use of technical means for diagnosing traction engines of rolling stock. *Modern Transportation Systems and Technologies*. 2024;10(4):556-576. doi: 10.17816/transsyst635142557
10. Salnikov SV, Solodkiy EM, Vishnyakov DD, et al. Diagnostika asinhronnogo dvigatel' na osnove mashinnogo obucheniya. In: *Proceedings of the XXVI International Conference on soft Computing and Measurements SCM-2023*. 2023 May 24-26. St. Petersburg: SPBGETU "LETI"; 2023.
11. Khalyasmaa A. Machine Learning as a Tool of High-Voltage Electrical Equipment Lifecycle Control Enhancement. *Proceedings of Irkutsk State Technical University*. 2020;24(5):1093-1094. doi: 10.21285/1814-3520-2020-5-1093-1104.
12. Korobeinikov AB, Sarvarov AS. Analysis Of Existing Methods for Diagnostics of Electric Motors and Perspectives of their Development. *Electrotechnical Systems and Complexes*. 2015;26(1):4-9. doi: 10.18503/2311-8318
13. Breiman L. *Random Forests*. *Machine Learning*. 2001;45(1):5-32. doi: 10.1023/A:1010933404324
14. Chen T, Guestrin C. XGBoost: A Scalable Tree Boosting System. In: *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. San Francisco: ACM; 2016:785-794.
15. Flakh P. *Mashinnoe obuchenie. Nauka i iskusstvo postroyeniya algoritmov kotorye izvlekaot znaniya iz dannyh*. Moscow: DMK Press; 2015. (In Russ.).
16. Kugaevskiy AV, Muromtsev DI, Kirsanova OV. *Klassicheskie Metody Mashinnogo Obucheniya*. St.-Petersburg: Universitet ITMO; 2022. (In Russ.)

Сведения об авторах:

Серёда Евгений Геннадьевич, кандидат технических наук, старший специалист;
eLibrary SPIN: 4284-3319;
E-mail: evgeniy.sereda@rackfork.ru

Соловьёв Андрей Сергеевич, аспирант, инженер по испытаниям;
eLibrary SPIN: 1594-5049; ORCID: 0009-0001-2408-1840;
E-mail: vgvhyjh@mail.ru

Information about the authors:

Evgeny G. Sereda, Cand. Sci. (Tech.), Senior specialist;
eLibrary SPIN: 4284-3319;
E-mail: evgeniy.sereda@rackfork.ru

Andrey S. Solovyov, Post graduate student, test engineer;
eLibrary SPIN: 1594-5049; ORCID: 0009-0001-2408-1840;
E-mail: vgvhyjh@mail.ru