

# Диагностика асинхронного двигателя на основе машинного обучения

С. В. Сальников, Е. М. Солодкий, Д. Д. Вишняков, Р. Ю. Юдин, А. Б. Петроченков  
Пермский национальный исследовательский политехнический университет  
kitkat980412@gmail.com

**Аннотация.** Данная работа включает комплексный анализ применимости методов машинного обучения для диагностики электропривода. Авторы рассмотрели методы выявления отказов асинхронных двигателей. Методы машинного обучения сравнивались с применением к этой задаче с дальнейшим выделением наиболее подходящих. Кроме того, в статье подробно рассказывается о предварительной обработке токов статора, которая может быть полезна для повторения полученных результатов. В результате сравнительного анализа, ансамбль классификаторов зарекомендовал себя как наиболее перспективный, показав высокую точность. Разработанная система характеризуется низкой стоимостью за счет использования всего двух измерительных датчиков тока и высокой надежностью, поэтому разработанная система может конкурировать с существующими на рынке решениями.

**Ключевые слова:** асинхронный двигатель, система диагностики, машинное обучение, классификатор, повреждение подшипника, межвитковое замыкание

## I. ВВЕДЕНИЕ

Асинхронный двигатель с короткозамкнутым ротором (АД) является самым распространенным типом электрических машин в мире. Согласно статистике, этот тип двигателя [1] потребляет 68 % всей электроэнергии, вырабатываемой в мире. Этот двигатель широко распространен, поскольку обладает высокой надежностью и ремонтопригодностью. Этот тип двигателя применим в широком спектре промышленных приложений. В то же время асинхронный двигатель подвержен износу и поломкам. Обычно это связано с условиями, в которых используется двигатель, также это связано с плохим обслуживанием двигателя. В промышленности существуют машины, которые требуют постоянного контроля [2]. Примером могут служить двигатели, которые участвуют в технологическом процессе непосредственно и не имеют резерва. Для постоянного контроля состояния оборудования обычно используются диагностические системы [3]. Часто эти системы требуют остановки двигателя для диагностики, тем самым не давая возможности диагностики двигателя в динамических режимах. Большая часть систем диагностики использует спектральный анализ тока двигателя [4], либо диагностика производится путем измерения механических и вибрационных параметров [5]. Использование диагностики путем анализа спектра тока статора обычно требует эксперта для анализа полученного спектра тока и определения неисправности [6]. Кроме того, диагностика асинхронного двигателя по сигнатуре тока может быть неприемлема при использовании в качестве источника питания преобразователя частоты (ПЧ), поскольку он может

вносить дополнительные искажения в спектр, вызванные широтно-импульсной модуляцией (ШИМ) [7].




Рис. 1. Блок-схема лабораторного стенда

Использование электромеханических методов диагностики, таких как датчики крутящего момента и скорости, также неприемлемо, поскольку эти типы датчиков подвержены механическому износу [8]. Поэтому перспективнее использовать диагностические системы, которые включают минимально возможное количество измерительного оборудования и делают заключение о состоянии двигателя без непосредственного участия человека.

Отказы асинхронных двигателей можно разделить на две категории – электрические и механические. Согласно статистике промышленного использования, до 37 % отказов связаны с обмоткой статора, а 41 % – с подшипниковым узлом [9]. Наиболее распространенным видом дефекта обмотки статора является межвитковое короткое замыкание в обмотке статора. Это состояние характеризуется соединением двух или более витков обмотки в местах, где повреждена изоляция.

## II. ЭКСПЕРИМЕНТАЛЬНОЕ ОБОРУДОВАНИЕ И СБОР ДАННЫХ

Для исследования применимости алгоритмов машинного обучения в рамках для диагностики АД был собран лабораторный стенд. Принцип работы лабораторного стенда описан на следующей схеме (рис. 1). Собранный стенд предоставляет следующие возможности: сбор, получение и сохранение токов статора двигателя.

Лабораторный стенд состоит из: преобразователя частоты (ПЧ), который подает питание на асинхронный двигатель (АД); автотрансформатора (АТ), который использовался для имитации межвиткового замыкания (две фазы соединены последовательно с обмотками статора, третья разомкнута); двигателя постоянного тока (ДПТ), который являлся нагрузочным устройством; датчиков тока (ДТ), встроенных в измерительное устройство (ИУ), которые использовались для измерения

токов двух фаз. Обработка и диагностика происходят на персональном компьютере (ПК). Собранный стенд изображен на рис. 2.



Рис. 2. Собранный лабораторный стенд

Естественный процесс разрушения подшипника занимает довольно много времени, поэтому дефекты были созданы искусственно. Для подготовки поврежденных подшипников заранее просверливались отверстия в наружной, внутренней и обеих обоймах. В результате имитировалось несколько повреждений подшипника (рис. 3). Разрушения наружного и внутреннего колец и их комбинация.

Далее, токи статора асинхронного двигателя были измерены при различных комбинациях режимов работы, с разными подшипниками и с различной степенью межвиткового короткого замыкания, было собрано 1035 временных рядов. Набор данных содержит 254 (24 %) образца для здорового двигателя, 275 (27 %) образцов для неисправной обмотки статора двигателя, 249 (24 %) образцов для неисправного подшипника двигателя и 257 (25 %) образцов для обеих неисправностей. Далее данные были разделены на тестовую и обучающую части, 311 (30 %) образцов – тестовые примеры, 724 (70 %) – обучающие примеры. В данных для обучения: 168 образцов – исправный двигатель; 167 образцов – двигатель с неисправностью подшипника; 184 образца – двигатель с неисправностью обмотки; 172 образца – двигатель с обеими неисправностями. В данных для тестирования: 86 образцов – исправный двигатель; 82 образца – двигатель с неисправностью подшипника; 91 образец – двигатель с неисправностью обмотки; 85 образцов – двигатель с обеими неисправностями.



Рис. 3. Поврежденные подшипники для лабораторного стенда



Рис. 4. Процесс обработки тока статора

### III. ПРЕДВАРИТЕЛЬНАЯ ОБРАБОТКА ТОКОВ СТАТОРА И ИЗВЛЕЧЕНИЕ ОСОБЕННОСТЕЙ

Для правильного использования алгоритмов машинного обучения необходимо предварительно обработать измеренные токи статора асинхронного двигателя. Весь процесс предварительной обработки представлен в виде блок-схемы (рис. 4).

#### A. Нормализация токов статора

Выходной сигнал датчика тока проходит через низкочастотный фильтр. Результат этого действия показан на рис. 5. Фильтр низких частот был реализован в виде FIR-фильтра с частотой среза 1 кГц, что достаточно для данного приложения. Для нормализации собранных данных все образцы должны иметь одинаковую размерность, которая определяется заданным числом периодов. Количество периодов было выбрано равным 4, что является достаточным для обнаружения любой из исследуемых аномалий. Для определения количества периодов использовалось определение угла положения тока статора и пересечения им нуля. Метод основан на анализе угла фазы тока статора, который вычислялся по следующему уравнению (принцип графически изображен на рис. 6):

$$\alpha = \arctan \frac{I_{\alpha}}{I_{\beta}} \quad (1)$$

#### B. Извлечение особенностей

Алгоритм использовался для поиска точек, заключенных между пятью последними переходами через ноль. После выполнения необходимых расчетов, описанных ранее, измеренные значения токов статора были нормализованы и приведены к одинаковой размерности выборки с помощью инструмента ресемплинга. Нормализованные токи представлены на рис. 7, 8.

Пакет Tsfresh предоставляет возможность автоматического расчета обширного количества характеристик (атрибутов) временных рядов, которыми в данном случае являются токи статора в двухфазных системах координат.




Рис. 5. Отфильтрованные токи статора




Рис. 6. Поиск переходов через ноль




Рис. 7. Сравнения статорных токов с неисправностью подшипника




Рис. 8. Сравнения статорных токов с межвитковым замыканием

Характеристики, которые вычисляет пакет, могут быть вполне стандартными, например, средние значения, максимум, минимум и медиана. В то же время встречаются и довольно экзотические, например, коэффициенты наклона линий тренда в различных окнах сигнала, амплитуды гармоник сигнала, фазовые характеристики сигнала. Однако большинство вычисленных характеристик являются избыточными для анализа тока статора.

Чтобы управлять количеством вычисляемых характеристик, данный инструментальный позволяет выбрать набор характеристик, описываемых следующим списком свойств: *Comprehensive* – самый широкий набор метрик, наиболее точно описывает временной ряд, но расчет может занять много времени; *Minimal* – основной набор, включающий основные статистические параметры, поверхностно описывает сигнал, но расчеты не занимают много времени. *Efficient* – почти тот же набор, что и *Comprehensive*, но не содержит метрик, которые требуют больших вычислительных затрат, может быть полезен для сокращения времени расчета.

Этот пакет также позволяет извлекать только релевантные характеристики на основе корреляции в пределах класса, к которому принадлежит образец. Однако эта функциональность не использовалась. Для извлечения характеристик использовался набор метрик *Efficient*, так как он является наиболее оптимальным с точки зрения времени вычислений и количества информации о полученных временных рядах. В результате для двух временных рядов (два тока статора) было вычислено в общей сложности 1578 признаков (метрик). В табл. 1 приведен пример извлеченных данных, параметры, начинающиеся с «альфа», рассчитаны для тока статора  $I_\alpha$ , «бета» –  $I_\beta$ .

#### IV. РАЗРАБОТАННЫЙ МЕТОД ДИАГНОСТИКИ

Цель диагностической системы – определить, исправен двигатель или поврежден, поэтому общий принцип идентификации неисправностей ИМ сводится к бинарной классификации для каждого типа неисправности. Таким образом, проблема сводится к поиску алгоритмов, обеспечивающих классификацию с приемлемой точностью. На практике для решения задачи идентификации неисправностей могут быть использованы различные алгоритмы ML.

#### A. Дерево решений

Правила генерируются автоматически в процессе обучения. Деревья решений как аналитические модели более интерпретируемы, чем нейронные сети. Процесс построения деревьев решений заключается в последовательном, рекурсивном разбиении обучающего множества на подмножества с применением правил принятия решений в узлах. Процесс разбиения продолжается до тех пор, пока все узлы в конце всех ветвей не будут объявлены листьями. Объявление узла листом может происходить естественным образом (когда он будет содержать единственный объект или объекты только одного класса) или по достижении некоторого условия останова, заданного пользователем (например, минимально допустимое количество примеров в узле или максимальная глубина дерева).

#### B. Метод случайного леса

Метод случайного леса (Random Forest) – это ансамбль из нескольких деревьев решений, который уменьшает проблему переобучения и повышает точность по сравнению с одним деревом. Прогноз получается путем агрегирования ответов множества деревьев. Деревья обучаются независимо друг от друга (на разных подмножествах), что не только решает проблему построения одинаковых деревьев на одном и том же наборе данных, но и делает этот алгоритм подходящим для распределенных вычислительных систем). [13]. При классификации результатом будет класс, за который проголосовало большинство деревьев, при условии, что одно дерево имеет один голос.

#### C. Алгоритм k-ближайших соседей

Для решения задачи классификации также используется метод k-ближайших соседей (kNN) [14]. Он относит объекты к тому классу, к которому относится большинство из k его ближайших соседей в многомерном пространстве признаков. Число k – это количество соседних объектов в пространстве признаков, которые сравниваются с классифицируемым объектом. Другими словами, если  $k = 5$ , то каждый объект сравнивается с 5 соседями.

#### D. Многослойный перцептрон

Многослойный перцептрон (MLP) [15] – это класс искусственных нейронных сетей прямого распространения, состоящих как минимум из трех слоев: входного, скрытого и выходного. MLP продемонстрировали способность находить приближенные решения для чрезвычайно сложных задач. В частности, они успешно используются при построении регрессионных моделей. Поскольку классификация может рассматриваться как частный случай регрессии, когда выходная переменная является категориальной, классификаторы могут быть построены на основе MLP.

#### Машина опорных векторов

Основная идея метода машины опорных векторов (SVM) [16] заключается в построении гиперплоскости, которая оптимальным образом разделяет объекты выборки. Алгоритм работает на основе предположения, что чем больше расстояние (разрыв) между разделяющей гиперплоскостью и объектами разделяемых классов, тем меньше будет средняя ошибка классификатора.

ТАБЛИЦА I. ИЗВЛЕЧЕННЫЕ ХАРАКТЕРИСТИКИ СИГНАЛОВ

Номер семпла	Альфа. Дубликаты минимальных значений	Альфа. Медиана	Альфа. Асимметрия	...	Альфа. Энтропия перестановок, порог 7, $\tau=1$	Альфа. Сходство запроса, порог 0.0
0	0.0	0.000000 4624	0.001091	...	1.062562	1.136935
1	0.0	- 0.000001 272	-0.000390	...	1.841313	2.044451
2	0.0	- 0.000000 1439	-0.001799	...	1.575958	1.757371
...	...	...	...	...	...	...
1034	0.0	- 0.000001 028	0.003073	...	2.085183	2.319195

**Градиентный буст и XGBoost**

Этот алгоритм основан на итеративном обучении деревьев решений с целью минимизации функции потерь. Благодаря особенностям деревьев решений, градиентный бустинг способен обрабатывать категориальные признаки и нелинейности. Алгоритм XGBoost [19] является усовершенствованной формой алгоритма градиентного бустинга. Однако XGBoost использует более регулярную формализацию, что позволяет повысить точность классификации.

*Е. Длительная кратковременная память*

Длительная кратковременная память (LSTM) [20] – это особый вид архитектуры рекуррентной нейронной сети (RNN), способной к обучению долгосрочным зависимостям. LSTM разработаны специально для того, чтобы избежать проблемы долгосрочной зависимости.

*Ф. Мультиклассовая классификация*

Система диагностики асинхронного двигателя должна выявлять неисправности подшипников и обмотки статора. Асинхронный двигатель может иметь четыре режима:

- обмотка исправна, подшипник исправен;
- обмотка исправна, подшипник поврежден;
- обмотка повреждена, подшипник исправен;
- обмотка повреждена, подшипник поврежден.

При такой постановке задачи она не может быть решена с помощью бинарной классификации. Эта проблема требует использования мультиклассовых подходов. Мультиклассовая классификация – это проблема отнесения объектов к одному из трех или более классов. Для разрабатываемого алгоритма был использован подход «Один против остальных»(OneVsRest). После предварительной обработки данных и извлечения признаков были использованы ранее описанные методы классификации. В качестве критерия эффективности была выбрана точность. Результаты использования различных методов с соответствующей точностью были собраны в табл. 2.

В результате наибольшую точность показал классификатор XGBoost. Поэтому было решено дополнительно оценить производительность этого классификатора для двух типов неисправностей. Матрицы ошибок показаны на рис. 9.




Рис. 9. Матрица ошибок для XGBoost классификатора при работе с реальными данными (для подшипникового узла – слева, для статорного узла – справа)

ТАБЛИЦА II. СРАВНЕНИЕ ТОЧНОСТИ КЛАССИФИКАТОРОВ С РЕАЛЬНЫМИ ДАННЫМИ

Классификатор	Точность
kNN	0.52
LSTM	0.51
Дерево решений	0.58
Random Forest	0.69
MLP	0.63
Градиентный бустинг	0.71
Наивный байесовский классификатор	0.46
SVM	0.59
XGBoost	0.72

**V. ЭКСПЕРИМЕНТАЛЬНЫЕ РЕЗУЛЬТАТЫ**

Классификатор для межвиткового замыкания дает лучшую точность. Это можно объяснить тем, что неисправность не оказывает прямого влияния на ток статора. В то время как межвитковое замыкание легче обнаружить по току статора, поскольку оно создает дисбаланс токов даже при небольшой степени повреждения. Для анализа качества работы классификатора также были построены ROC-кривые (рис. 10). Рассчитанные метрики были отражены в табл. 3.




Рис. 10. ROC кривые для XGBoost классификатора с реальными данными (для подшипникового узла – слева, для статорного узла – справа)

ТАБЛИЦА III. МЕТРИКИ ДЛЯ XGBOOST КЛАССИФИКАТОРА

Метрика	Поломка подшипника	Поломка статора
<b>Precision</b>	0.77	0.91
<b>Recall</b>	0.73	0.84
<b>F1</b>	0.75	0.87
<b>AUC</b>	0.87	0.96
<b>Accuracy</b>	0.76	0.88

Для достижения большей точности классификации был выбран ансамблевый подход. Для построения ансамбля были выбраны наиболее точные модели, включая Random forest, MLP, Gradient boost и XGBoost. матрицы ошибок, представленные на рис. 11. Кроме того, дополнительно были построены ROC-кривые (рис. 12), метрики которых отражены в табл. 4.

В итоге удалось добиться улучшения всех характеристик качества классификатора. Для уменьшения количества признаков была проведена оценка их важности. Так, было установлено, что 48 из 1578 признаков для диагностики подшипникового (рис. 13) и 42 из 1578 для статорного узла (рис. 14) могут быть использованы без потери качества классификатора.

ТАБЛИЦА IV. МЕТРИКИ ДЛЯ АНСАМБЛЯ КЛАССИФИКАТОРОВ

Метрика	Поломка подшипника	Поломка статора
Precision	0.82	0.95
Recall	0.75	0.88
F1	0.79	0.91
AUC	0.90	0.96
Accuracy	0.79	0.91




Рис. 11. Матрица ошибок для ансамбля классификаторов с реальными данными (для подшипникового узла – слева, для статорного узла – справа)




Рис. 12. ROC кривые для ансамбля классификаторов с реальными данными (для подшипникового узла – слева, для статорного узла – справа)




Рис. 13. Выбранные особенности для классификатора статорного узла




Рис. 14. Выбранные особенности для классификатора статорного узла

## VI. ЗАКЛЮЧЕНИЕ

В данной работе рассматриваются методы идентификации отказов асинхронных двигателей. Проведено сравнение методов машинного обучения в применении к данной задаче с последующим выделением наиболее подходящих. Согласно результатам исследования, алгоритмы машинного обучения показали лучшее качество классификации, чем подходы глубокого обучения. В данной реализации это может быть связано со специфической предварительной обработкой данных, поскольку временные ряды тока статора практически идентичны в различных режимах работы двигателя. Будущие исследования будут включать в себя тестирование различных подходов к предварительной обработке данных для улучшения текущего решения. В результате работы были получены удовлетворительные результаты при использовании ансамбля классификаторов. Этот ансамбль был построен из классификаторов, которые показали наибольшую эффективность из всех протестированных. Рассчитанные характеристики подтверждают это. Кроме того, разработанная система имеет перспективы для промышленного внедрения, так как проблема особенно актуальна для ответственных двигателей в промышленном производстве. Система характеризуется низкой стоимостью за счет использования всего двух датчиков измерительного тока и высокой надежностью, поэтому разработанная система может конкурировать с существующими на рынке продуктами.

## СПИСОК ЛИТЕРАТУРЫ

- [1] P. Waide and C. U. Brunner, "Energy-efficiency policy opportunities for electric motor-driven systems," 2011.
- [2] W. Wang and D. D. Li, "Health condition monitoring of induction motors," in *Induction Motors-Applications, Control and Fault Diagnostics*, IntechOpen, 2015.
- [3] A. Siddique, G. Yadava, and B. Singh, "A review of stator fault monitoring techniques of induction motors," *IEEE transactions on energy conversion*, vol. 20, no. 1, pp. 106–114, 2005.
- [4] D. Miljkovic, "Brief review of motor current signature analysis," *HD- KBR Info magazin*, vol. 5, no. 1, pp. 14–26, 2015.
- [5] C. Wang and J. Lai, "Vibration analysis of an induction motor," *Journal of sound and vibration*, vol. 224, no. 4, pp. 733–756, 1999.
- [6] W. T. Thomson and M. Fenger, "Current signature analysis to detect induction motor faults," *IEEE Industry Applications Magazine*, vol. 7, no. 4, pp. 26–34, 2001.
- [7] F. Villada, D. Cadavid, N. Mun'oz, D. Valencia, and D. Parra, "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.*, pp. 229–234, IEEE, 2003.
- [8] Y. Azzoug, A. Menacer, R. Pusca, R. Romary, T. Ameid, and A. Ammar, "Fault tolerant control for speed sensor failure in induction motor drive based on direct torque control and adaptive stator flux observer," in *2018 International Conference on Applied and Theoretical Electricity (ICATE)*, pp. 1–6, IEEE, 2018.
- [9] S. L.-D. J. Bama-BIRO' and K. A' goston, "Rotor faults detection in squirrel-cage induction motors by current signature analysis," 2004.
- [10] M. Christ, N. Braun, J. Neuffer, and A. W. Kempa-Liehr, "Time series feature extraction on basis of scalable hypothesis tests (tsfresh—a python package)," *Neurocomputing*, vol. 307, pp. 72–77, 2018.
- [11] G. vanRossum, "Python reference manual," *Department of Computer Science [CS]*, no. R 9525, 1995.
- [12] L. Breiman, J. H. Friedman, R. A. Olshen, and C. J. Stone, *Classification and regression trees*. Routledge, 2017.
- [13] G. Biau and E. Scornet, "A random forest guided tour," *Test*, vol. 25, no. 2, pp. 197–227, 2016.

- [14] A. Singh, A. Yadav, and A. Rana, "K-means with three different distance metrics," *International Journal of Computer Applications*, vol. 67, no. 10, 2013.
- [15] L. Noriega, "Multilayer perceptron tutorial," *School of Computing. Staffordshire University*, p. 34, 2005.
- [16] H. Wang and D. Hu, "Comparison of svm and ls-svm for regression," in *2005 International conference on neural networks and brain*, vol. 1, pp. 279–283, IEEE, 2005.
- [17] K. M. Leung, "Naive bayesian classifier," *Polytechnic University Department of Computer Science/Finance and Risk Engineering*, vol. 2007, pp. 123–156, 2007.
- [18] A. Natekin and A. Knoll, "Gradient boosting machines, a tutorial," *Frontiers in neurorobotics*, vol. 7, p. 21, 2013.
- [19] T. Chen, T. He, M. Benesty, V. Khotilovich, Y. Tang, H. Cho, K. Chen, et al., "Xgboost: extreme gradient boosting," *R package version 0.4-2*, vol. 1, no. 4, pp. 1–4, 2015.
- [20] S. Hochreiter and J. Schmidhuber, "Long short-term memory," *Neural computation*, vol. 9, no. 8, pp. 1735–1780, 1997.