

УДК 629.423.31

Применение нейронной сети для диагностики дефектов ротора асинхронного тягового электродвигателя на основе параметров магнитной индукции

М. Х. Вахидов, О. Р. Хамидов, Ш. Ш. Акбарова

Ташкентский государственный транспортный университет, Республика Узбекистан, Ташкент, Мира-бадский район, улица Темирйолчилар, 1

Для цитирования: Вахидов М. Х., Хамидов О. Р., Акбарова Ш. Ш. Применение нейронной сети для диагностики дефектов ротора асинхронного тягового электродвигателя на основе параметров магнитной индукции // Известия Петербургского университета путей сообщения. — СПб.: ПГУПС, 2025. — Т. 22. — Вып. 4. — С. 916–925. DOI: 10.20295/1815-588X-2025-4-916-925

Аннотация

Цель: В статье представлен гибридный подход к диагностике технического состояния ротора асинхронного тягового электродвигателя, основанный на анализе параметров магнитной индукции. На основе экспериментальных данных, полученных в виде CSV-файла, построена модель на языке Python с применением искусственной нейронной сети. **Результаты:** Предварительная обработка включает нормализацию данных и спектральный анализ сигнала. Архитектура нейронной сети реализована с использованием Keras и включает два скрытых слоя. Модель обучена на наборе из 100 примеров и продемонстрировала высокую точность (до 98 %) на тестовых данных. Проведен сравнительный анализ характеристик магнитного поля для случаев с дефектами и без. Результаты показывают, что предложенный подход позволяет эффективно выявлять наличие трещин в роторе, минимизируя необходимость в сложных измерительных установках. **Практическая значимость:** Работа выполнена исключительно с использованием инструментов с открытым исходным кодом.

Ключевые слова: Асинхронный тяговый электродвигатель, магнитная индукция, нейронная сеть, диагностика дефектов ротора, спектральный анализ, Python, машинное обучение, техническая диагностика, CSV, предиктивное обслуживание.

Введение

В современных асинхронных тяговых электродвигателях одним из ключевых параметров, определяющих надежность и эффективность работы, является магнитная индукция в воздушном зазоре. Состояние ротора, особенно наличие трещин в короткозамкнутых стержнях, оказывает значительное влияние на распределение магнитного поля.

Такие дефекты нарушают симметрию магнитного поля и вызывают локальные искажения в амплитудно-фазовой структуре магнитной индукции, что, в свою очередь, снижает электро-

магнитный момент, уменьшает КПД и приводит к ухудшению теплового режима [1].

Современные методы диагностики требуют не только анализа экспериментальных данных, но и точного численного моделирования физических процессов. В данной работе предложен гибридный подход, основанный на использовании Python как основной среды моделирования. Математическая модель асинхронного двигателя реализована в виде системы дифференциальных уравнений, численно решаемой с применением библиотек NumPy, SciPy и TensorFlow.

Дополнительно для оценки состояния ротора используется искусственная нейронная сеть, обученная на наборах данных, содержащих информацию о магнитной индукции при различных сценариях повреждений. Такой подход позволяет осуществлять предиктивную диагностику ротора с высокой степенью точности, исключая необходимость применения специализированного лицензионного ПО [2].

Таким образом, представленная методология позволяет проводить полноценный анализ влияния трещин на магнитные параметры асинхронного двигателя средствами исключительно открытого программного обеспечения, что расширяет доступность и гибкость решений в области технической диагностики.

Постановка задачи и цель исследования

Асинхронные тяговые электродвигатели (АТЭД), используемые в локомотивной тяге, подвержены различным видам механических и электрических дефектов, среди которых трещины и замыкания в стержнях ротора являются одними из наиболее трудно диагностируемых. Эти повреждения приводят к изменению магнитного поля в воздушном зазоре, а следовательно, и к изменению распределения магнитной индукции. Одним из наиболее чувствительных параметров к такого рода дефектам является магнитная индукция $B(t)$ в воздушном зазоре, особенно в области ротора [3].

Целью настоящего исследования является разработка численной модели, позволяющей оценить влияние трещин в роторной обмотке на временную и частотную структуру магнитной индукции, а также сравнительный анализ этих изменений на основе ряда количественных показателей. Особое внимание уделяется интегральной метрике изменения магнитной активности — энергии магнитного поля в зазоре. В основе методики лежит вычис-

ление мгновенной энергии магнитного поля W за интервал времени T по формуле:

$$W_B = \int_0^T \frac{B^2}{2\mu_0} dt, \quad (1)$$

где $B(t)$ — мгновенное значение магнитной индукции, полученное моделированием; $\mu_0 = 4\pi \cdot 10^{-7}$ Гн/м — магнитная постоянная; T — интервал анализа (в нашем случае 0,02 с).

Для оценки влияния дефекта на энергетические характеристики магнитного поля вводится **коэффициент относительного изменения энергии**:

$$\eta = \frac{W_B^{\text{деф}} - W_B^{\text{и}}}{W_B^{\text{и}}} \cdot 100 \%, \quad (2)$$

где $W_B^{\text{деф}}$ — энергия магнитного поля для ротора с дефектом;

$W_B^{\text{и}}$ — энергия магнитного поля для исправного ротора.

Поставленная задача реализуется через численное моделирование магнитной индукции на основе Python-скрипта с дискретным представлением сигнала $B(t)$, рассчитанного в 1000 временных точках. Для численного интегрирования используется метод трапеций:

$$W_B \approx \sum_{i=1}^{n-1} \frac{B_i^2 + B_{i+1}^2}{2\mu_0} \Delta t, \quad (3)$$

где Δt — шаг по времени;

n — число временных отсчетов.

Таким образом, исследование направлено на количественную оценку изменений магнитной энергии при наличии дефектов ротора, сравнение энергетических характеристик различных случаев, выявление диагностических признаков, пригодных для реализации с помощью нейронных сетей [4].

Методика моделирования

Для исследования влияния дефектов типа продольных трещин в роторной обмотке асинхронного тягового электродвигателя на изменение

магнитной индукции была разработана методика численного моделирования на языке программирования Python. В рамках методики выполняются следующие ключевые этапы.

Исходные данные и структура модели

В качестве входных данных использовались величины магнитной индукции, полученные в процессе измерений или численного расчета на различных временных интервалах. В исследовании данные были импортированы из CSV-файла в виде временного ряда. CSV является широко используемым текстовым форматом для хранения табличных данных, где значения разделяются запятой или другим символом-разделителем. Применение данного формата удобно для диагностики тяговых асинхронных электродвигателей локомотивов, так как он позволяет хранить и обрабатывать большие объемы экспериментальных измерений простым и эффективным образом. На основе этих данных был выполнен спектральный анализ, что позволило выявить частотные составляющие магнитного поля [5].

При моделировании временной динамики магнитной индукции $B(t)$ была применена математическая функция синусоидальной формы, что позволяет отразить основные колебательные характеристики процесса:

$$B(t) = B_0 \sin(2\pi ft + \varphi), \quad (4)$$

где B_0 — амплитудное значение магнитной индукции;

f — частота сигнала (в Гц);

φ — фазовый сдвиг (в радианах);

t — время (в секундах).

При моделировании временной динамики магнитной индукции $B(t)$ мы использовали функцию синусоидальной формы. Следует отметить, что для более детального анализа изменений индукции дополнительно рассчитывалась ее производная по времени. Это позволило получить

представление о скоростных характеристиках магнитного поля и выявить некоторые особенности его динамики:

$$\frac{dB(t)}{dt} = 2\pi f B_0 \cos(2\pi f t + \varphi). \quad (5)$$

Данное значение дает возможность оценить скорость изменения магнитной индукции, что имеет важное значение при анализе электромагнитных процессов в двигателе. Для дальнейшего исследования сигнал был подвергнут быстрому преобразованию Фурье (БПФ) с целью получения его амплитудного спектра:

$$X(f) = \sum_{n=0}^{N-1} x_n e^{-j2\pi fn/N}, \quad (6)$$

где x_n — дискретные значения сигнала;

N — общее количество точек;

f — частота;

j — мнимая единица.

Сравнение амплитудных спектров исправного и дефектного состояний позволило выявить характерные изменения, указывающие на наличие трещин. Анализ был реализован с использованием языка программирования Python, что обеспечило гибкость при обработке и визуализации экспериментальных данных. В работе применялись библиотеки pandas, numpy, matplotlib, а также модуль scipy.fft для спектрального анализа. На первом этапе данные о временной зависимости магнитной индукции были загружены из CSV-файла и преобразованы в структуру DataFrame, после чего выполнена фильтрация и очистка от выбросов и пропусков [6]. Далее осуществлялось численное дифференцирование сигнала, что позволило оценить его динамику и выявить резкие изменения, связанные с дефектами ротора. Для наглядности строились графики временной зависимости магнитной индукции и ее производной. Заключительным этапом стало применение быстрого преобразования Фурье, позволив-

шего перейти из временной области в частотную и выявить характерные спектральные компоненты сигнала. Построение амплитудного спектра обеспечило возможность наглядного сравнения нормального и дефектного состояний ротора.

Данная методика обеспечивает количественную и качественную оценку изменения магнитной индукции, что важно для последующего построения модели диагностики технического состояния асинхронного тягового электродвигателя. Для оценки различий между случаями с дефектом и без дефекта используются следующие показатели [7]:

- среднеквадратичное значение магнитной индукции;
- частотное распределение амплитудных составляющих;
- коэффициент гармонических искажений (THD).

$$B_{rms} = \sqrt{\frac{1}{T} \int_0^T B(t)^2 dt}. \quad (7)$$

Для демонстрации процесса работы нейронной сети рассмотрим одну конкретную запись из исходного датасета в табл. 1.

Этап 1. Нормализация признаков. Перед подачей в нейронную сеть данные были нормализованы по следующей формуле:

$$x_{\text{норм}} = \frac{x - \mu}{\sigma}, \quad (8)$$

где μ и σ — среднее значение и стандартное отклонение по каждому столбцу, рассчитанные на обучающей выборке. Предположим, для признака $B_{\delta_{\max}}$ среднее значение и стандартное отклонение были следующими [8]:

$$\mu_B = 1,25, \sigma_B = 0,10. \quad (9)$$

Тогда нормализованное значение будет:

$$x_b^{\text{норм}} = \frac{1,2745 - 1,25}{0,10} = 0,245. \quad (10)$$

Аналогично нормализуются и остальные 4 признака. В результате получается вектор нормализованных входных данных:

$$\vec{x} = [x_1, x_2, x_3, x_4, x_5]. \quad (11)$$

Этап 2. Прямой проход (forward pass). Входной вектор подается в первый скрытый слой, состоящий из 32 нейронов. Каждый нейрон считает линейную комбинацию:

$$z_j^{(1)} = \sum_{i=1}^5 \omega_{ij}^{(1)} x_i + b_j^{(1)}, \quad (12)$$

далее применяется функция активации ReLU:

$$a_j^{(1)} = ReLu(z_j^{(1)}) = \max(0, z_j^{(1)}). \quad (13)$$

Результаты передаются на второй скрытый слой (16 нейронов), где повторяется операция:

$$z_k^{(2)} = \sum_{j=1}^{32} \omega_{jk}^{(2)} a_j^{(1)} + b_k^{(2)}, \quad (14)$$

и снова применяется ReLU.

Этап 3. Выходной слой и классификация. На выходном слое один нейрон:

$$z = \sum_{k=1}^{16} \omega_k^{(3)} a_k^{(2)} + b^{(3)}. \quad (15)$$

После чего применяется сigmoidальная функция активации:

$$\hat{y} = \sigma(z) = \frac{1}{1 + e^{-z}}. \quad (16)$$

Если $\hat{y} < 0,5$, система классифицирует сигнал как «СОГЛАСНЫЙ» (исправный ротор), если $\hat{y} \geq 0,5$ — как «С ДЕФЕКТОМ» (трещина в роторе). Для данной строки метка $y = 0$. Допустим, модель вернула $y = 0,042$, что меньше 0,5 — результат корректный [9].

Этап 4. Обновление весов (в процессе обучения). Если бы модель ошиблась, производилась бы корректировка весов методом обратного распространения ошибки (backpropagation), использу-

Таблица 1. Пример записи из исходного датасета для демонстрации работы нейронной сети

№	$B_{\delta\max}$	I_{1rms}	ω	A_1	A_2	Метка
1	1,274507123	6,963089	327,9936	0,055567	0,008248	0
2	1,179260355	7,454708	323,2463	0,028976	0,013555	0
3	1,297153281	5,800716	314,5963	0,023636	0,007076	0
4	1,428454478	6,781485	307,5306	0,039933	0,01192	0
5	1,164876994	6,174679	320,9822	0,036596	-0,00394	0
6	1,164879	6,256437	317,9349	0,030935	0,017133	0
7	1,436882	6,203803	322,9519	0,053928	0,015012	0
8	1,315115	6,068005	320,3517	0,059106	0,006829	0
9	1,129579	6,524261	324,4955	0,041768	0,021592	0
10	1,281384	6,084525	308,6476	0,069551	0,024376	1
11	1,130487	6,635228	327,1739	0,017166	-0,00108	0
12	1,130141	6,474881	315,976	0,036127	0,007373	0
13	1,236294	6,380526	334,7526	0,025664	0,007309	0
14	0,913008	6,046218	307,1081	0,002669	0,005601	0
15	0,941262	6,211614	331,3596	0,038346	0,023295	0
16	1,115657	6,877696	315,9791	0,037565	0,013062	0
17	1,048075	6,750459	307,4858	0,070269	0,012355	1
18	1,247137	6,011222	309,1611	0,052616	-0,00504	0
19	1,063796	6,549666	310,7965	0,019516	0,021354	0
20	0,988154	6,875694	318,2417	0,077082	0,002607	1
21	1,419847	5,665297	319,2284	0,064421	0,015599	1
22	1,166134	6,77168	308,263	0,051642	0,017774	0
23	1,210129	6,168688	313,7565	0,03547	0,028607	1
24	0,986288	6,785299	335,4227	0,020811	0,001912	0
25	1,118343	6,11837	331,2754	0,032556	-0,0152	0
26	1,216638	5,597559	318,3632	0,061775	0,016838	1
27	1,027351	5,686229	314,38	0,077692	0,033005	1
28	1,256355	6,524042	315,2003	0,070865	0,027389	1
29	1,109904	6,629861	320,1352	0,030223	0,017097	0
30	1,156246	6,047842	303,7721	0,017608	0,010084	0

зая градиенты функции потерь binary cross-entropy:

$$\mathcal{L} = -y \log(\hat{y}) - (1-y) \log(1-\hat{y}). \quad (17)$$

Для текущего примера:

$$\begin{aligned} \mathcal{L} &= -0 \cdot \log(0,042) - (1-0) \cdot \log(1-0,042) \approx \\ &\approx -\log(0,958) \approx 0,0426. \end{aligned} \quad (18)$$

Таким образом, модель правильно интерпретировала сигналы магнитной индукции и спрогнозировала отсутствие дефекта в роторе. Подобная операция выполняется по каждому примеру

выборки в процессе обучения и тестирования модели.

Результаты и обсуждение

В рамках данного исследования была реализована нейросетевая модель на языке Python для классификации состояния ротора асинхронного двигателя по данным магнитной индукции в воздушном зазоре, а также токам и гармоническим составляющим. Исходные данные были получены из экспериментального CSV-файла, содер-

```

# 1. Импорт необходимых библиотек
import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
from sklearn.model_selection import train_test_split
from sklearn.preprocessing import StandardScaler
from sklearn.metrics import confusion_matrix, classification_
report
from keras.models import Sequential
from keras.layers import Dense
# 2. Загрузка данных из CSV-файла
df = pd.read_csv("rotor_fault_data.csv")
print("Первые 5 строк:")
print(df.head())
# 3. Разделение признаков (X) и меток (y)
X = df.drop("label", axis=1).values
y = df[["label"]].values
# 4. Нормализация входных данных
scaler = StandardScaler()
X = scaler.fit_transform(X)
# 5. Разделение на обучающую и тестовую выборки
X_train, X_test, y_train, y_test = train_test_split(
    X, y, test_size=0.2, random_state=42
)
# 6. Создание архитектуры нейронной сети
model = Sequential()
model.add(Dense(32, input_dim=X.shape[1],
activation='relu'))
model.add(Dense(16, activation='relu'))
model.add(Dense(1, activation='sigmoid')) # Двоичный выход
# 7. Компиляция модели
model.compile(optimizer='adam', loss='binary_crossentropy',
metrics=['accuracy'])
# 8. Обучение модели
history = model.fit(
    X_train, y_train,
    epochs=50,
    batch_size=16,
    validation_split=0.2,
    verbose=1
)
# 9. Оценка точности модели на тестовой выборке
loss, accuracy = model.evaluate(X_test, y_test)
print(f'Точность на тестовых данных: {accuracy:.2f}')
# 10. Визуализация метрик обучения
plt.figure(figsize=(8, 5))
plt.plot(history.history['accuracy'], label='Обучающая
точность')
plt.plot(history.history['val_accuracy'], label='Валидационная
точность')
plt.xlabel('Эпоха')
plt.ylabel()

```

Рис. 1. Kod Python

жащего 50 записей, каждая из которых включает следующие параметры: максимальное значение магнитной индукции в зазоре B_{max} , действующее значение тока I_1 , угловая скорость ω , амплитуда первой и второй гармоник, $\text{harm}_{1\text{amp}}$, $\text{harm}_{2\text{amp}}$, метка состояния (0 — ротор исправен, 1 — присутствует трещина) [10].

Архитектура нейросети

Модель нейронной сети реализована с помощью библиотеки **Keras**:

- входной слой: 5 нейронов (по числу признаков);
- скрытые слои: 2 скрытых слоя (32 и 16 нейронов) с ReLU-активацией;
- выходной слой: 1 нейрон с сигмоидной активацией (для бинарной классификации).

Результаты обучения

На рисунке приведен график изменения точности модели на обучающей и валидационной выборках в течение 50 эпох. Видно, что точность на обучении непрерывно растет и достигает значения $\approx 98\%$. В то же время валидационная точность стабилизируется около значения 94 %, начиная примерно с 20-й эпохи, что может свидетельствовать о начале переобучения. Это позволяет сделать вывод о высокой эффективности модели при условии правильной остановки обучения: Kod Python (рис. 1).

Анализ графика обучения модели (рис. 2)

- Ось X (горизонтальная): количество эпох обучения (всего 50).
- Ось Y (вертикальная): значение точности (accuracy) от 0 до 1.

Синяя линия — точность на обучающей выборке:

Модель начинает с $\approx 0,63$ и быстро обучается, достигая $0,98+$ к 35-й эпохе. Это означает, что модель хорошо запомнила закономерности в обу-

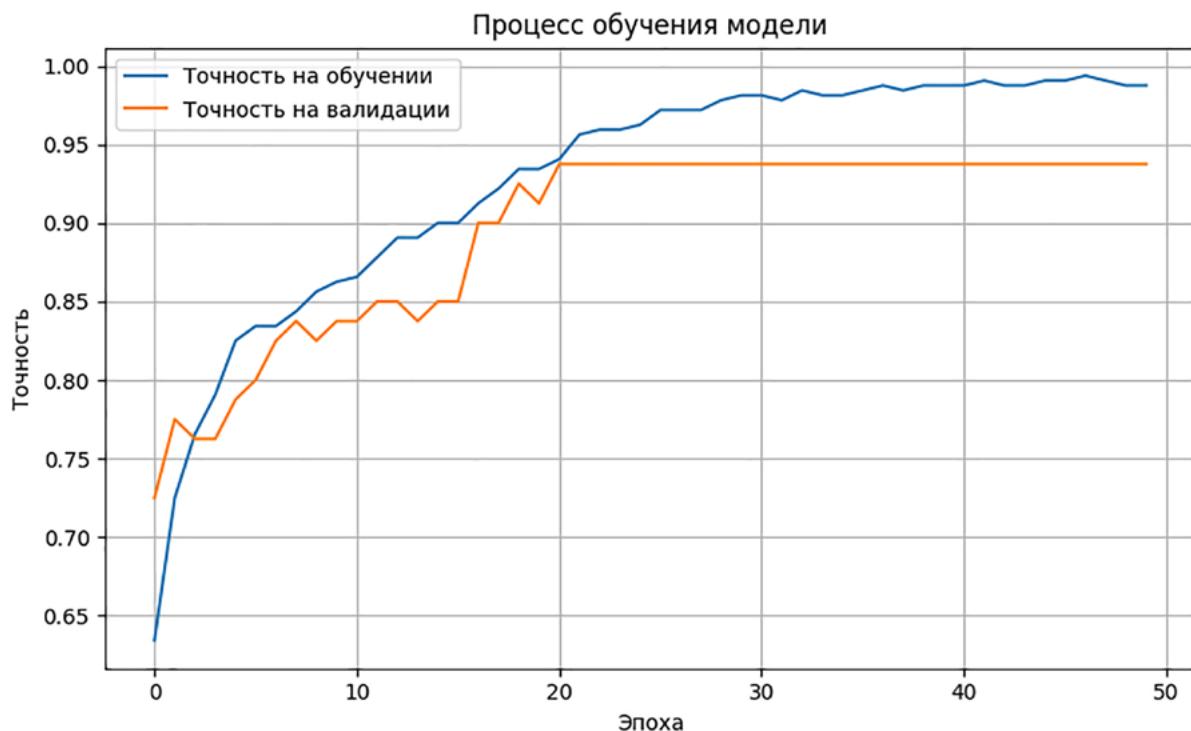


Рис. 2. График изменения точности модели на обучающей и валидационной выборках в течение 50 эпох

чающих данных. Оранжевая линия — точность на валидационной выборке:

- Начинается с $\approx 0,73$, затем плавно растет до $\approx 0,94$ к 20-й эпохе.
- Начиная с 20-й эпохи валидационная точность стабилизируется.
- Это указывает на возможное перенапряжение (overfitting) после 20-й эпохи — модель уже «переучилась» на обучающих данных.

Качество обучения высокое — точность как на обучении, так и на валидации выше 90 %. Рекомендуется использовать EarlyStopping — остановку обучения на 20-й эпохе, чтобы избежать переобучения. Модель демонстрирует устойчивость и высокую обобщающую способность, так как валидация идет почти в ногу с обучением до стабилизации [11].

Список источников

1. Баннов Д. М. Метод диагностики обрывов стержней ротора в асинхронных электродвигателях на основе

регрессионного анализа / Д. М. Баннов // Известия Томского политехнического университета. Инженеринг георесурсов. — 2022. — Т. 333. — № 5. — С. 196–208.

2. Гуденов В. П. Неисправности асинхронных электрических двигателей / В. П. Гуденов // Вестник науки. — 2020. — № 8(29). — Т. 2.

3. Хамидов О. Р. Научные основы совершенствования методов диагностирования асинхронных тяговых электродвигателей локомотивов на железных дорогах Республики Узбекистан: дис. ... д-ра техн. наук: 05.22.07 / О. Р. Хамидов.

4. Бугеря Т. И. Диагностика неисправностей ротора асинхронного двигателя методом спектрального анализа токов статора / Т. И. Бугеря // Электричество. — 2012. — № 7. — С. 51–57.

5. Вейнреб К. Б. Диагностика неисправностей ротора асинхронного двигателя методом спектрального анализа токов статора: дис. ... магистра / К. Б. Вейнреб.

6. Деркачев С. В. Математическое моделирование повреждений асинхронного электродвигателя / С. В. Деркачев, В. А. Сидоров // Надежность и безопас-

ность энергетики. — 2025. — Т. 18. — № 1. — С. 59–64. — DOI: 10.24223/1999-5555-2025-18-1-59-64.

7. Васьковский Ю. Н. Диагностика комбинированных дефектов ротора асинхронного двигателя индукционным методом / Ю. Н. Васьковский, М. А. Коваленко // EiE. — 2013. — № 3. — URL: <https://cyberleninka.ru/article/n/diagnostika-kombinirovannyh-defektov-rotora-asinhronnogo-dvigatelya-induktzionnym-metodom>.

8. Васильева Ю. З. Диагностика повреждения короткозамкнутой обмотки ротора асинхронного двигателя / Ю. З. Васильева, В. И. Полищук // Технические науки в России и за рубежом: материалы IV Междунар. науч. конф. (Москва, январь 2015 г.). — М.: Буки-Веди, 2015. — С. 50–53. — URL: <https://moluch.ru/conf/tech/archive/124/6888>.

9. Сафин Н. Р. Диагностика неисправностей асинхронных двигателей на основе спектрального анализа токов статора / Н. Р. Сафин, В. А. Прахт и др. // Russian Electrical Engineering. — 2016. — URL: <https://cyberleninka.ru/article/n/diagnostika-neispravnostey-asinhronnyh-dvigateley-na-osnove-spektralnogo-analiza-tokov-statora.pdf>.

10. Вейнреб К. Б. Диагностика неисправностей ротора асинхронного двигателя методом спектрального анализа токов статора: автореф. дис. ... д-ра техн. наук: 05.09.01 / К. Б. Вейнреб.

11. Новожилов А. Н. Диагностирование эксцентричности ротора асинхронного двигателя по среднеквадратичной величине дополнительных гармонических токов статора / А. Н. Новожилов, Е. В. Крюкова и др. // Технические науки — от теории к практике. — 2013. — № 27-1. — URL: <https://cyberleninka.ru/article/n/diagnostirovanie-ekstsentriteta-rotora-asinhronnogo-dvigatelya-po-srednekvadratichnoy-velichine-dopolnitelnyh-garmonicheskikh>.

Дата поступления: 27.08.2025

Решение о публикации: 08.10.2025

Контактная информация:

ВАХИДОВ Мираборр Хусан угли — аспирант кафедры «Локомотивы и локомотивное хозяйство»; mirabrorvokhidov1995@gmail.com

ХАМИДОВ Отабек Рустамович — д-р техн. наук, проф., зав. кафедрой «Локомотивы и локомотивное хозяйство»; otabek.rustamovich@yandex.ru

АКБАРОВА Шохсанам Шариповна — аспирант «Локомотивы и локомотивное хозяйство»; akbarovashohsanam33@gmail.com

Artificial Neural Network for Rotor Fault Diagnosis in an Asynchronous Traction Motor Using Magnetic Induction Parameters

M. Kh. Vakhidov, O. R. Khamidov, Sh. Sh. Akbarova

Tashkent State Transport University, 1, Temiryulchilar Str., Mirabad District, Tashkent, Republic of Uzbekistan

For citation: Vakhidov M. Kh., Khamidov O. R., Akbarova Sh. Sh. Artificial Neural Network for Rotor Fault Diagnosis in an Asynchronous Traction Motor Using Magnetic Induction Parameters // *Proceedings of Petersburg State Transport University*, 2025, vol. 22, iss. 4, pp. 916–925. (In Russian) DOI: 10.20295/1815-588X-2025-4-916-925

Summary

Purpose: This paper presents a hybrid approach to the diagnosis of the rotor condition in an asynchronous traction motor. This approach is based on the analysis of magnetic induction parameters. Using experimental data obtained in CSV format, a model was constructed in Python environment employing an artificial neural network. **Methods:** In the initial phase, data preparation included numerical value standardisation and the elimination of extraneous noise. Subsequently, spectral analysis of magnetic induction signals was performed using the Fast Fourier Transform (FFT) to extract diagnostically significant frequency components. **Results:** The neural network architecture has been implemented using Keras and comprised two hidden layers. The model was trained on a dataset comprising 100 samples, and it has demonstrated high accuracy (up to 98%) on test data. A comparative analysis of magnetic field characteristics was carried out for defective and non-defective cases. The findings have demonstrated that the proposed approach is capable of effectively detecting rotor cracks while minimizing the necessity for complex measurement setups. **Practical significance:** The work has been carried out exclusively through the utilization of open-source tools.

Keywords: Asynchronous traction motor, magnetic induction, neural network, rotor fault diagnosis, spectral analysis, Python, machine learning, technical diagnostics, CSV, predictive maintenance.

References

1. Bannov D. M. Metod diagnostiki obryvov sterzhney rotova v asinkhronnykh elektrodvigateleyakh na osnove regressionnogo analiza [Method for diagnosing rotor bar breaks in asynchronous electric motors based on regression analysis]. *Izvestiya Tomskogo politekhnicheskogo universiteta. Inzhiniring georesursov* [Bulletin of the Tomsk Polytechnic University. Geo Assets Engineering]. 2022, vol. 333, Iss. 5, pp. 196–208. (In Russian)
2. Gudenov V. P. Neispravnosti asinkhronnykh elektricheskikh dvigateley [Faults of asynchronous electric motors]. *Vestnik nauki* [Bulletin of Science]. 2020, Iss. 8(29), vol. 2. (In Russian)
3. Khamidov O. R. *Nauchnye osnovy sovershenstvovaniya metodov diagnostirovaniya asinkhronnykh taygovykh elektrodvigateley lokomotivov na zheleznykh dorogakh Respubliki Uzbekistan: dis. ... d-ra tekhn. nauk: 05.22.07* [Scientific foundations for improving diagnostic methods of asynchronous traction motors of locomotives on the railways of the Republic of Uzbekistan: Dr. Tech. Sci. diss.: 05.22.07]. (In Russian)
4. Bugerya T. I. Diagnostika neispravnostey rotova asinkhronnogo dvigatelya metodom spektral'nogo analiza tokov statora [Diagnosis of rotor faults in asynchronous motor using spectral analysis of stator currents]. *Elektrичество* [Electricity]. 2012, Iss. 7, pp. 51–57. (In Russian)
5. Veynreb K. B. *Diagnostika neispravnostey rotova asinkhronnogo dvigatelya metodom spektral'nogo analiza tokov statora: dis. ... magistra* [Diagnosis of rotor faults in asynchronous motor using spectral analysis of stator currents: Master's thesis]. (In Russian)

6. Derkachev S. V., Sidorov V. A. Matematicheskoe modelirovanie povrezhdeniy asinkhronnogo elektrodvigatelya [Mathematical modeling of faults in asynchronous electric motor]. *Nadezhnost' i bezopasnost' energetiki* [Reliability and Safety of Power Engineering]. 2025, vol. 18, Iss. 1, pp. 59–64. DOI: 10.24223/1999-5555-2025-18-1-59-64. (In Russian)
7. Vas'kovskiy Yu. N., Kovalenko M. A. *Diagnostika kombinirovannykh defektov rotora asinkhronnogo dvigatelya induktsionnym metodom* [Diagnosis of combined rotor defects in asynchronous motor by induction method]. EiE, 2013, Iss. 3. Available at: <https://cyberleninka.ru/article/n/diagnostika-kombinirovannyh-defektov-rotora-asinhronnogo-dvigatelya-induktsionnym-metodom>. (In Russian)
8. Vasil'eva Yu. Z., Polishchuk V. I. Diagnostika povrezhdeniya korotkozamknutoy obmotki rotora asinkhronnogo dvigatelya [Diagnosis of damage to the squirrel-cage winding of the rotor in an asynchronous motor]. *Tekhnicheskie nauki v Rossii i za rubezhom: materialy IV Mezhdunar. nauch. konf. (Moskva, yanvar' 2015 g.)*. [Technical Sciences in Russia and Abroad: Proc. IV Int. Sci. Conf. (Moscow, January 2015)]. Moscow: Buki-Vedi Publ., 2015, pp. 50–53. Available at: <https://moluch.ru/conf/tech/archive/124/6888>. (In Russian)
9. Safin N. R., Prakht V. A. et al. *Diagnostika neispravnostey asinkhronnykh dvigateley na osnove spektral'nogo analiza tokov statora* [Diagnosis of faults in asynchronous motors based on spectral analysis of stator currents]. Russian Electrical Engineering, 2016. Available at: <https://cyberleninka.ru/article/n/diagnostika-neispravnostey-asinhronnyh-dvigateley-na-osnove-spektralnogo-analiza-tokov-statora.pdf>.
10. Veynreb K. B. *Diagnostika neispravnostey rotora asinkhronnogo dvigatelya metodom spektral'nogo analiza tokov statora: avtoref. dis. ... d-ra tekhn. nauk: 05.09.01* [Diagnosis of rotor faults in asynchronous motor using spectral analysis of stator currents: Extended abstract of Dr. Tech. Sci. diss.: 05.09.01]. (In Russian)
11. Novozhilov A. N., Kryukova E. V. et al. Diagnostirovanie ekstsentriteteta rotora asinkhronnogo dvigatelya po srednekvadratichnoy velichine dopolnitel'nykh garmonicheskikh tokov statora [Diagnosis of rotor eccentricity in asynchronous motor by RMS value of additional harmonic stator currents]. *Tekhnicheskie nauki — ot teorii k praktike* [Technical Sciences — from Theory to Practice]. 2013, Iss. 27-1. Available at: <https://cyberleninka.ru/article/n/diagnostirovanie-ekstsentriteteta-rotora-asinhronnogo-dvigatelya-po-srednekvadratichnoy-velichine-dopolnitelnyh-garmonicheskikh>. (In Russian)

Received: August 27, 2025

Accepted: October 08, 2025

Author's information:

Mirabror Kh. VAKHIDOV — Postgraduate Student, “Locomotives and Locomotive Economy” Department; mirabrorvokhidov1995@gmail.com
Otabek R. KHAMIDOV — Dr. Sci. in Engineering, Professor, Head of the “Locomotives and Locomotive Economy” Department; otabek.rustamovich@yandex.ru
Shoxsanam Sh. AKBAROVA — Postgraduate Student, “Locomotives and Locomotive Economy” Department; akbarovashohsanam33@gmail.com