

621.313.333.004.5:004.85

DOI: <https://doi.org/10.18664/ikszt.v30i3.351250>

ЗМІЙ С.О., доцент кафедри автоматики та комп'ютерного телекерування рухом поїздів, кандидат технічних наук, Український державний університет залізничного транспорту.

ПРИЛИПКО А.А., доцент кафедри автоматики та комп'ютерного телекерування рухом поїздів, кандидат технічних наук, Український державний університет залізничного транспорту.

СОСУНОВ О.О., доцент кафедри автоматики та комп'ютерного телекерування рухом поїздів, кандидат технічних наук, Український державний університет залізничного транспорту.

ЩЕБЛИКІНА О.В., доцент кафедри автоматики та комп'ютерного телекерування рухом поїздів, PhD, Український державний університет залізничного транспорту.



Діагностика асинхронного двигуна з використанням зняття зубцевих характеристик та обробки даних з використанням штучного інтелекту

Анотація. У статті розглядається інноваційний підхід до діагностики асинхронних двигунів, які є ключовими компонентами в промисловості та на залізничному транспорті, зокрема в системах автоматики та телекерування рухом поїздів. Запропонований метод базується на глибокому аналізі зубцевих гармонік у спектрі струму статора (Motor Current Signature Analysis, MCSA), що дозволяє проводити моніторинг стану двигуна в реальному часі без необхідності його зупинки.

В роботі детально описано методологію, що починається зі збору даних струму статора за допомогою високочастотної дискретизації, продовжується виділенням та нормуванням зубцевих гармонік, частоти яких залежать від параметрів двигуна (кількості пазів статора та ротора, числа пар полюсів та частоти мережі). Особлива увага приділяється ідентифікації характерних частот, пов'язаних з різними видами несправностей, таких як ексцентриситет повітряного зазору (статичний та динамічний), а також пошкодження обмоток або механічні дефекти.

Центральним елементом запропонованої системи є інтеграція штучного інтелекту, а саме багатошарової нейронної мережі прямого поширення (MLP), для автоматизованої обробки та класифікації отриманих спектральних даних. Вхідний шар мережі приймає вектор ознак, що включає нормовані амплітуди зубцевих та бічних гармонік. Для навчання мережі використовується метод зворотного поширення помилки з функцією втрат крос-ентропії та функцією активації ReLU у прихованих шарах, а вихідний шар використовує Softmax для класифікації чотирьох основних станів: нормальна робота, статичний ексцентриситет, динамічний ексцентриситет, та пошкодження обмоток.

Наведені результати моделювання, проведені на асинхронному двигуні потужністю 5,5 кВт, підтверджують ефективність підходу. Експерименти включали симуляцію нормального стану, статичного та динамічного ексцентриситету, демонструючи значне зростання амплітуд характерних гармонік при наявності дефектів. Нейромережа, навчена на 1000 спектрах, досягла точності класифікації 94% на тестовій вибірці.

Запропонований метод дозволяє не лише значно підвищити точність діагностики, але й забезпечити її оперативність, що є критично важливим для запобіжного обслуговування, зменшення експлуатаційних витрат та збільшення терміну служби обладнання в умовах безперервної роботи транспортних систем.

© ЗМІЙ С. О., ПРИЛИПКО А.А., СОСУНОВ О.О., ЩЕБЛИКІНА О. В., 2025

Хоча метод чутливий до точного визначення параметрів двигуна та шумів, його подальший розвиток передбачає інтеграцію додаткових діагностичних ознак, таких як вібрація та температура, для подальшого підвищення надійності системи.

Ключові слова: Асинхронний двигун, діагностика, зубцеві гармоніки, спектральний аналіз, Motor Current Signature Analysis (MCSA), штучний інтелект, нейронна мережа, ексцентриситет повітряного зазору, пошкодження обмоток, прогностичне обслуговування

Вступ

Асинхронні двигуни (АД) є фундаментальною складовою сучасної промисловості, а їхня роль на залізничному транспорті набуває особливого значення. Вони широко використовуються в різноманітних системах, включаючи приводи стрілочних переводів, вентиляцію тунелів, системи енергопостачання та допоміжні механізми рухомого складу. Зокрема, надійність роботи АД у приводах стрілочних переводів є критичною для забезпечення безперебійного та безпечного руху поїздів. Незважаючи на притаманну їм міцність та простоту конструкції, АД піддаються зношенню, зазнають механічних дефектів та можуть виходити з ладу внаслідок експлуатаційних впливів. Будь-яка несправність такого двигуна у системі керування стрілкою може призвести до затримок руху, порушення графіку перевезень та, найважливіше, до створення аварійних ситуацій, що безпосередньо загрожують безпеці пасажирів та вантажів.

Традиційні методи діагностики, такі як візуальний огляд або вимірювання опору обмоток, часто є інвазивними та вимагають зупинки обладнання. У контексті залізничного транспорту, де безперервність руху є пріоритетом, планове виведення з експлуатації стрілочного переводу для діагностики є вкрай небажаним і призводить до суттєвих операційних втрат. Це створює нагальну потребу у розробці та впровадженні неінвазивних методів моніторингу, які дозволяють проводити діагностику стану АД у реальному часі, без переривання їхньої роботи.

Аналіз зубцевих гармонік у спектрі струму статора (Motor Current Signature Analysis, MCSA) є одним з найбільш перспективних напрямків для вирішення цієї проблеми. Цей метод ґрунтується на принципі, що будь-які відхилення у фізичному стані двигуна – такі як ексцентриситет повітряного зазору, пошкодження обмоток або інші механічні

несправності – викликають появу або зміну характерних гармонік у спектрі споживаного струму. Виявлення цих "сигнатур" на ранніх стадіях дозволяє своєчасно вжити запобіжних заходів, запобігаючи серйозним поломкам та їхнім негативним наслідкам.

Сучасні досягнення у сфері штучного інтелекту (ШІ), зокрема розвиток нейронних мереж, відкривають нові можливості для автоматизації та значного підвищення точності аналізу діагностичних даних. Інтеграція алгоритмів машинного навчання дозволяє створити інтелектуальні системи, здатні самостійно розпізнавати складні патерни в спектральних даних, що робить процес діагностики більш об'єктивним та швидким. Застосування ШІ мінімізує вплив людського фактора та дозволяє оперативно виявляти несправності, що є ключовим для забезпечення високого рівня безпеки та ефективності перевізного процесу.

Метою цієї роботи є розробка та обґрунтування методу діагностики асинхронних двигунів для залізничного транспорту, який базується на комплексному використанні аналізу зубцевих характеристик струму статора та нейромережевої обробки даних із застосуванням штучного інтелекту.

Діагностика асинхронного двигуна з використанням зняття зубцевих характеристик та обробки даних нейромережею з використанням штучного інтелекту

Аналіз сигнатури струму двигуна (MCSA) є потужною, неінвазивною технікою моніторингу стану, яка аналізує спектр струму статора для ідентифікації специфічних гармонічних компонентів, пов'язаних з несправностями. Цей підхід дозволяє проводити діагностику в реальному часі без переривання роботи двигуна. MCSA є особливо ефективним для діагностики несправностей, що викликають коливання крутного моменту або швидкості, що робить його ідеальним для аналізу різноманітних несправностей двигунів. [1]

Сучасні досягнення в галузі штучного інтелекту, зокрема в нейронних мережах, відкривають нові можливості для автоматизації та значного підвищення точності діагностичних процесів на основі MCSA. Глибокі моделі навчання, такі як багатосаровий перцептрон (MLP), використаний у цій методології, можуть ефективно класифікувати складні стани двигуна, мінімізуючи втручання людини та підвищуючи точність діагностики. [2]

Поєднання MCSA та ШІ створює потужний синергетичний ефект для прогностичного обслуговування. MCSA надає багаті, але часто

складні та тонкі дані про сигнатури несправностей. III, особливо глибоке навчання, чудово розпізнає закономірності у багатовимірних, зашумлених даних. Таким чином, ця комбінація виходить за рамки традиційної інтерпретації MCSA людськими експертами, дозволяючи створити більш надійну, автономну та потенційно більш чутливу систему виявлення несправностей. Це означає перехід від реактивного або планового обслуговування до справжнього прогностичного обслуговування, де тонкі зміни можуть бути виявлені на ранніх стадіях, запобігаючи катастрофічним збоям та оптимізуючи графіки технічного обслуговування. [3]

Зубцеві гармоніки виникають унаслідок природної взаємодії магнітних полів статора і ротора, які залежать від геометричних особливостей двигуна. Характеристики залежать від кількості пазів статора (N_s) та ротора (N_r). Частоти цих гармонік (f_{zh}) можуть бути розраховані за формулою

$$f_{zh} = f_1 \cdot \left(k \cdot \frac{N_r}{p} \pm 1 \right), \quad (1)$$

де f_1 – частота живильної мережі;

k – порядковий номер гармоніки ($k=0,1,2,\dots$);

p – число пар полюсів;

N_r – число пазів ротора.

При ексцентриситеті повітряного зазору (статичному або динамічному) амплітуда гармонік зростає. Для динамічного ексцентриситету з'являються додаткові бічні частоти (f_{de}), які розраховуються як

$$f_{de} = f_1 \pm m \cdot f_r \quad (2)$$

де $f_r = n/60$ – частота обертання ротора (в Гц);

n – швидкість обертання (об/хв);

m – ціле число.

Загальний сигнал струму статора $I(t)$ може бути представлений як сума його гармонійних складових

$$I(t) = I_1 \sin(2\pi f_1 t) + \sum_k I_{zh,k} \sin(2\pi f_{zh,k} t + \phi_k)$$

де I_1 – амплітуда основної гармоніки;

$I_{zh,k}$ – амплітуда зубцевої гармоніки порядку k ;

ϕ_k – фазовий зсув.

Умови несправності, такі як статичний або динамічний ексцентриситет повітряного зазору,

ідентифікуються за помітним зростанням амплітуди специфічних гармонік у спектрі струму статора. Наприклад, в експериментальному дослідженні ексцентриситет призвів до збільшення амплітуд гармонік на частотах $f_{zh}=350$ Гц та $f_{zh}=650$ Гц. Експериментальна установка включає асинхронний двигун потужністю 5,5 кВт з $p=2$ парами полюсів, $N_r=28$ пазами ротора та частотою живильної мережі $f_1=50$ Гц.

Цей підхід підкреслює важливість простору ознак, заснованого на фізичних принципах. Вирази (1) та (2) не є довільними частотами, а безпосередньо виводяться з фізичних параметрів двигуна. Це означає, що процес вилучення ознак полягає не просто у застосуванні загального швидкого перетворення Фур'є (FFT), а у виявленні *специфічних, фізично значущих* частот. Такий підхід до інженерії ознак, заснований на фізиці, є вирішальним. Він зменшує розмірність задачі, робить ознаки більш інтерпретованими та, ймовірно, покращує здатність нейронної мережі до узагальнення, оскільки вона навчається на сигналах, безпосередньо пов'язаних з основними механізмами несправностей, а не на довільних спектральних компонентах. Це ключова відмінність від чисто керованих даними моделей "чорної скриньки".

Також важливо враховувати чутливість MCSA до параметрів двигуна та умов експлуатації. Точність діагностичної системи сильно залежить від точного знання конструктивних параметрів двигуна та його робочої швидкості. Якщо ці параметри невідомі або значно змінюються під час роботи (наприклад, для двигунів зі змінною швидкістю), фіксовані частотні діапазони для виявлення несправностей будуть неточними. Це вказує на необхідність або надійного модуля оцінки параметрів, або адаптивного відстеження частотних діапазонів для реального розгортання, що є значним викликом, який виходить за рамки цієї конкретної роботи, але є вирішальним для практичного застосування. [4]

Початковий крок у діагностичній методології передбачає вимірювання сигналу струму статора за допомогою відповідних датчиків струму. Важливо, що частота дискретизації (f_s) системи збору даних повинна відповідати критерію Найквіста, тобто бути щонайменше вдвічі більшою за максимальну очікувану частоту зубцевих гармонік ($f_s > 2f_{zh,max}$). Якщо найвища очікувана частота несправності не

буде адекватно захоплена, виникне аліасинг, що призведе до неправильної діагностики. Це означає, що проектування системи збору даних (вибір датчиків, АЦП та частоти дискретизації) має бути ретельно узгоджене з теоретичними частотами несправностей. Глибший наслідок полягає в тому, що для двигунів з більшою кількістю полюсів або вищими швидкостями $f_{zh,max}$ буде вищою, що вимагає вищих частот дискретизації, що, своєю чергою, впливає на вимоги до зберігання та обробки даних. Це створює практичне обмеження на проектування системи.

Основні етапи діагностування.

Етап виділення зубцевих характеристик діагностичної моделі зосереджений на перетворенні "сирого" сигналу струму статора в набір кількісних ознак, які є чутливими до певних несправностей асинхронного двигуна. Суть процесу полягає у виявленні та кількісній оцінці специфічних частотних складових, які виникають у струмі двигуна при наявності дефектів.

Перетворення сигналу в частотну область полягає у використанні спектрального аналізу. Сигнал струму статора, який є часовою функцією $I(t)$, перетворюється з часової області в частотну. Це дозволяє розкласти складний сигнал на його складові гармоніки, виявивши основні та додаткові частоти, а також їхні амплітуди. Для цього застосовується швидке перетворення Фур'є (FFT). Результатом є спектр, який відображає амплітуду кожної частотної складової. [10]

Перед виконанням спектрального аналізу до сигналу застосовується віконна функція (наприклад, вікно Хеммінга). Це робиться для покращення "роздільної здатності" отриманого спектра та зменшення ефекту "витоку спектра" (spectral leakage). Витік спектра може призвести до розмиття піків та утруднення точного визначення амплітуд гармонік, особливо тих, що мають низьку амплітуду або знаходяться близько до інших, сильніших складових. Віконна функція "згладжує" краї тимчасового сегменту, який аналізується, зменшуючи штучні артефакти в спектрі. [11]

Ідентифікація та кількісна оцінка гармонік несправностей. При наявності дефектів, таких як ексцентриситет повітряного зазору, амплітуди цих гармонік зростають. Їхні частоти можна розрахувати за (1).

Окрім зубцевих гармонік, при деяких типах несправностей, зокрема при динамічному ексцентриситеті повітряного зазору, у спектрі струму з'являються додаткові бокові частоти (f_{de}). Ці частоти

пов'язані з частотою обертання ротора (f_r). Зростання амплітуд цих складових є прямим індикатором динамічного ексцентриситету.

Для отримання уніфікованих ознак, які менш чутливі до змін навантаження або напруги живлення, амплітуди виявлених зубцевих та бічних гармонік нормуються. Це зазвичай виконується шляхом ділення амплітуди гармоніки несправності на амплітуду основної гармоніки струму (I_1)

$$A_{zh,k} = \frac{|X(f_{zh,k})|}{I_1},$$

де $X(f_{zh,k})$ — амплітуда зубцевої гармоніки порядку k .

На завершення етапу формування вектора ознак всі виділені та нормовані амплітуди характерних гармонік, а також відповідні частоти бокових складових, об'єднуються в єдиний вектор ознак. Цей вектор є кількісним представленням стану двигуна і служить вхідними даними для наступного етапу – нейромережевої обробки. Таким чином, складний часовий сигнал трансформується в компактний числовий формат, який може бути ефективно оброблений алгоритмами штучного інтелекту.

Етап нейромережевої обробки є інтелектуальним ядром розробленої діагностичної моделі, що забезпечує автоматичну класифікацію стану асинхронних двигунів на основі виділених спектральних ознак. Він ґрунтується на принципах штучного інтелекту, зокрема на використанні нейронних мереж.

Для реалізації класифікації несправностей використовується багатошарова нейронна мережа прямого поширення (MLP). Цей тип мереж складається з послідовно розташованих шарів нейронів, де інформація рухається лише в одному напрямку – від вхідного шару до вихідного. [12]

На вхідний шар мережі подається вектор ознак (F). Цей вектор містить кількісні дані, отримані на попередньому етапі виділення зубцевих характеристик: нормовані амплітуди зубцевих гармонік ($A_{zh,k}$) та частоти додаткових бічних гармонік (f_{de}). Кількість елементів у цьому векторі відповідає кількості проаналізованих гармонік та бічних частот.

Між вхідним та вихідним шарами розташовані приховані шари.

Вихідний шар мережі призначений для класифікації стану двигуна.

Навчання мережі є ключовим етапом, під час якого вона вчиться розпізнавати патерни, що відповідають різним несправностям.

Розроблення моделі та дослідження результатів з використанням MATLAB

Запропонована нейронна мережа є програмною моделлю, реалізованою в середовищі MATLAB за допомогою функцій Deep Learning Toolbox. Вона складається з послідовності шарів, кожен з яких виконує певні математичні операції над вхідними даними, щоб навчитися розпізнавати патерни, пов'язані з різними станами двигуна. [13] Вибір архітектури MLP та функцій активації відображає баланс між простотою та складністю задачі. Ця архітектура, хоча і ефективна, свідчить про те, що вилучені ознаки (вектор F) є достатньо дискримінаційними, і складна архітектура глибокого навчання (як-от CNN або LSTM, згадані в [13] для інших застосувань) не є абсолютно необхідною. Це означає, що етапи MCSA та інженерії ознак виконують значну частину "важкої роботи" з перетворення сирих сигналів у лінійно розділюваний простір ознак. Якби ознаки були складнішими або мали притаманні просторові/часові залежності, знадобилася б інша, більш спеціалізована архітектура мережі. Це підкреслює, що "модель" – це не лише нейронна мережа, а весь конвеєр, де інженерія ознак відіграє вирішальну роль у спрощенні завдання класифікації для MLP.

У розробленій моделі використовується три прихованих шари, кожен з яких містить 64 нейрони. Нейрони в цих шарах застосовують функцію активації ReLU ($f(x)=\max(0, x)$). ReLU обрано за його обчислювальну ефективність та здатність зменшувати проблему зникаючих градієнтів. Ця функція допомагає мережі вивчати складні нелінійні залежності у вхідних даних, що є критично важливим для точного розпізнавання різноманітних станів двигуна.

Таблиця 1. Архітектура багатошарового перцептрона та параметри навчання

Параметр / Компонент	Опис	Значення / Конфігурація	Функція / Інструментарій MATLAB
Тип мережі	Багатошаровий перцептрон	-	Deep Learning Toolbox
Вхідний шар	Приймає вектор ознак F	$F=[A_{zh,l}, \dots, A_{zh,m}, f_{de,l}, \dots]$	-

Вихідний шар використовує функцію активації Softmax, яка є стандартною для задач багатокласової класифікації, перетворюючи сирі вихідні дані в ймовірності для кожного класу. Мережа класифікує стани двигуна на: нормальну роботу, статичний ексцентриситет, динамічний ексцентриситет та пошкодження обмоток.

Deep Learning Toolbox MATLAB надає комплексне середовище для проектування, впровадження та симуляції глибоких нейронних мереж. Він пропонує різні функції та інструменти для визначення шарів мережі, включаючи інтерактивне проектування за допомогою програми Deep Network Designer. Інструментарій також сприяє взаємодії, дозволяючи імпорт/експорт моделей з/до інших фреймворків, таких як PyTorch, TensorFlow та ONNX. [13]

Нейронна мережа навчається за допомогою алгоритму зворотного поширення помилки (backpropagation), стандартного методу оновлення ваг мережі для мінімізації помилок прогнозування. Метою навчання є мінімізація функції втрат крос-ентропії, яка зазвичай використовується для завдань класифікації

$$L = - \sum_i y_i \log(\hat{y}_i),$$

де y_i — справжня мітка класу;

$\hat{y}_i$ — передбачена ймовірність.

У проведеному дослідженні нейромережа навчалася на 1000 спектрах струму, що охоплювали різні стани двигуна. Кожен приклад у навчальній вибірці складається з вектора ознак (вхід) та відповідної "правильної" мітки класу (бажаний вихід). Параметри нейромережі зведені до таблиці 1.

Приховані шари	Кількість та нейрони на шар	3 шари, по 64 нейрони кожен	-
Функція активації прихованих шарів	Нелінійна функція	ReLU ($f(x)=\max(0, x)$)	-
Вихідний шар	Функція активації для класифікації	Softmax	-
Класи вихідних даних	Класифікація станів двигуна	Нормальна робота, статичний ексцентриситет, динамічний ексцентриситет, пошкодження обмоток	-
Метод навчання	Алгоритм оптимізації ваг	Зворотне поширення помилки (Backpropagation)	Trainnet [14]
Функція втрат	Метрика для мінімізації помилок	Крос-ентропія	trainnet, trainingOptions [14]
Оптимізатор	Алгоритм оновлення ваг	Наприклад, Adam (типово в trainingOptions)	trainingOptions [14]
Розмір навчального набору даних	Кількість спектрів для навчання	1000 спектрів	-

Дослідження проводилося на асинхронному двигуні з параметрами: потужність 5,5 кВт, число пар полюсів $p=2$, число пазів ротора $N_r=28$, а частота живильної мережі $f_l=50$ Гц. Були змодельовані три основні стани:

- нормальна робота – еталонний стан без дефектів.
- статичний ексцентриситет імітувався зміщенням 0,3 мм.
- динамічний ексцентриситет імітувався вигином вала на 0,2 мм.

Збір даних струму статора виконувався з частотою дискретизації $f_s=10$ кГц, а тривалість запису становила 10 секунд для кожного стану.

Проведена MATLAB-симуляція генерує два основні типи візуалізацій: графіки струму статора в часовій області та його спектри в частотній області. Ці візуалізації дозволяють покроково аналізувати

діагностичний процес, від сирого сигналу до виявлення прихованих несправностей.

Графіки струму статора (рисунок 1) в часовій області (Current Waveforms in Time Domain) відображають миттєві значення струму статора у функції часу для кожного змодельованого стану асинхронного двигуна.

Візуально оцінити наявність та тип несправності дуже складно. Це зумовлено тим, що основна гармоніка струму, що відповідає частоті живильної мережі (50 Гц), має значно більшу амплітуду порівняно з гармоніками, що виникають через несправності. Зубцеві гармоніки та бічні смуги, які є індикаторами дефектів, зазвичай мають амплітуди, що становлять лише невеликий відсоток (зазвичай менше 1%) від амплітуди основної гармоніки. Ці малі спотворення майже непомітні на загальному синусоїдальному сигналі. Крім того,

людське око не здатне розрізняти такі незначні зміни форми сигналу, особливо у присутності незначних шумів або операційних флуктуацій.

Графік нормальної роботи показує практично ідеальний, чистий синусоїдальний сигнал, що відповідає стабільній та бездефектній роботі двигуна.

При статичному ексцентриситеті сигнал залишатиметься переважно синусоїдальним. Можуть бути присутні дуже легкі та ледь помітні модуляції амплітуди, які викликані нерівномірністю повітряного зазору, але вони зазвичай не помітні без ретельного аналізу.

Динамічний ексцентриситет може з'явитися дуже тонка амплітудна модуляція основного сигналу, що повторюється з частотою обертання ротора. Ця модуляція, хоч і існує, але, як правило, настільки мала, що її візуальна ідентифікація в часовій області є ненадійною.

Залежно від ступеня та типу пошкодження, можуть спостерігатися незначні спотворення синусоїдальної форми, такі як легка асиметрія або поява "шуму" на вершинах/западах. Однак, знову ж таки, для більшості реальних випадків ці спотворення є візуально незначними.




Рисунок 1. Графіки струму статора

Таким чином графіки в часовій області наочно демонструють ключову причину застосування спектрального аналізу – неможливість точної та надійної діагностики несправностей асинхронних двигунів лише на основі візуального спостереження за формою струму.

Спектри струму статора (Current Spectra in Frequency Domain) є результатом швидкого перетворення Фур'є сигналу струму статора і відображає амплітуди різних частотних складових. Вісь X представляє частоту (в Герцах), а вісь Y – амплітуду (в Амперах), часто в логарифмічному

масштабі (semilog) для кращого виділення низькоамплітудних гармонік.




Рисунок 2. Спектри струму статора

Спектральний аналіз є фундаментальним для виявлення прихованих несправностей, оскільки він дозволяє виділити характерні частоти. Несправності генерують специфічні частотні складові (гармоніки), які розраховуються на основі параметрів двигуна, зростання амплітуд цих характерних гармонік є прямим індикатором розвитку дефекту.

На спектрі при нормальній роботі буде домінувати один яскраво виражений пік на частоті живильної мережі ($f_i = 50$ Гц). Амплітуди зубцевих гармонік (f_{zh}) будуть присутні, але на мінімальному, "фоновому" рівні, відображаючи нормальну електромагнітну взаємодію ротора і статора. Бічні частоти (f_{de}) будуть відсутні або матимуть вкрай низькі амплітуди.

Ключовою ознакою статичного ексцентриситета буде значне зростання амплітуд певних зубцевих гармонік. У результатах моделювання це проявляється зростанням амплітуд гармонік на частотах, наприклад, 350 Гц та 650 Гц. Ці збільшення амплітуд свідчать про нерівномірність повітряного зазору, спричинену статичним зміщенням ротора.

Динамічний ексцентриситет на додаток до зростання амплітуд зубцевих гармонік, найбільш характерною ознакою є поява або значне збільшення амплітуд додаткових бокових частот. Ці бічні смуги

розташовуються навколо основної гармоніки та/або зубцевих гармонік і є прямим індикатором динамічних дефектів ротора, таких як вигин вала або його дисбаланс.

Спектр при пошкодженні обмоток може показати зростання амплітуд на інших характерних частотах, які не завжди є зубцевими гармоніками, але пов'язані з асиметрією обмоток або іншими електричними дефектами. Наприклад, можуть з'явитися або значно збільшитися амплітуди гармонік, кратних основній частоті ($2f_i$, $3f_i$, тощо), або інших характерних частот, що виникають при міжвиткових замиканнях або обривах фаз.

Дані, отримані на етапі нейромережевої обробки, відображають ефективність та точність навченої моделі ІІІ. Ці дані критично важливі для оцінки надійності та придатності моделі для використання в реальних системах автоматики. Для візуалізації процесу навчання та результатів використано графічний інструмент nntaintool MATLAB.

Ефективність розробленої діагностичної моделі була підтверджена шляхом її тестування на даних, отриманих у процесі симуляції. Основною метою було переконатися, що нейронна мережа здатна коректно класифікувати стани асинхронного двигуна, використовуючи лише спектральні ознаки, виділені зі струму статора. Для навчання нейронної

мережі було сформовано навчальний набір, що включав 1000 спектрів, згенерованих для різних станів. Кожен спектр був перетворений у вектор ознак, що містив нормовані амплітуди діагностичних гармонік, які подавалися на вхід нейромережі.

Ключовим результатом є оцінка ефективності навченої мережі на тестовій вибірці, яка складалася з даних, що не використовувалися під час навчання. Точність класифікації, досягнута моделлю, склала 94%. Цей показник свідчить про високу здатність нейронної мережі до узагальнення та правильного розпізнавання несправностей на основі аналізу спектральних ознак.

Висновок

Запропонований у роботі метод діагностики асинхронних двигунів, що базується на комплексному аналізі спектральних характеристик струму статора та застосуванні нейромереж, демонструє високу ефективність і є перспективним для впровадження у критично важливих системах, зокрема на залізничному транспорті.

Аналіз сигнатури струму двигуна є потужною неінвазивною технікою, яка дозволяє виявляти несправності АД на ранніх стадіях без зупинки обладнання. Він ґрунтується на фізичних принципах, що пов'язують геометричні та електричні параметри двигуна з характерними гармоніками у спектрі струму, такими як зубцеві гармоніки та бічні частоти. Інтеграція багатошарової нейронної мережі для класифікації станів двигуна дозволила досягти високої точності. В ході симуляцій, нейромережа, навчена на 1000 спектрах, показала точність класифікації 94% на тестовій вибірці. Це підтверджує, що модель здатна ефективно розпізнавати складні патерни несправностей на основі векторів ознак, сформованих з спектральних даних.

Розроблений метод дозволяє перейти від планового чи реактивного обслуговування до справжнього прогностичного обслуговування. Оперативне та точне виявлення дефектів, таких як ексцентриситет повітряного зазору чи пошкодження обмоток, є критично важливим для мінімізації ризиків аварій, скорочення часу простоїв стрілочних переводів, зменшення експлуатаційних витрат та підвищення загального рівня безпеки руху.

Визначено, що точність діагностики залежить від точного знання конструктивних параметрів двигуна. У подальшому розвитку моделі планується інтеграція додаткових діагностичних ознак, таких як

дані вібрації та температури, що дозволить підвищити надійність системи та зробити її більш стійкою до змін умов експлуатації та шумів.

Розроблений метод є подальшим розвитком існуючих діагностичних підходів [15, 16]. Запропонований підхід є значним кроком у напрямку створення автономних та інтелектуальних систем моніторингу, які є запорукою ефективного та безпечного функціонування залізничного транспорту.

Список використаних джерел

1. Motor Current Signature Analysis for Gear Train Fault Detection [Електронний ресурс] // MATLAB & Simulink. – Режим доступу: <https://www.mathworks.com/help/predmaint/ug/motor-current-signature-analysis-for-gear-train-fault-detection.html>. – Дата звернення: 20.07.2025.
2. Jawad Faiz, Farbod Parvin. Recent Advances in Fault Diagnosis Methods for Electrical Motors- A Comprehensive Review with Emphasis on Deep Learning // AUT Journal of Electrical Engineering AUT J. Electr. Eng., 56(1) (Special Issue) (2024) 79-94 2024. Vol. 20, No. 1. P.79-91. DOI: 10.22060/ej.2023.22675.5558.
3. Majid Hussain, Tayab Din Memon, Imtiaz Hussain, Zubair Ahmed Memon, Dileep Kumar. Fault Detection and Identification Using Deep Learning Algorithms in Induction Motors // Computer Modeling in Engineering & Sciences. CMES, 2022, vol.133, no.2. P.435-470. <http://dx.doi.org/10.32604/cmcs.2022.020583>
4. de las Morenas, J.; Moya-Fernández, F.; López-Gómez, J.A. The Edge Application of Machine Learning Techniques for Fault Diagnosis in Electrical Machines. *Sensors* 2023, 23, 2649. <https://doi.org/10.3390/s23052649>
5. Rohullah Rahmatullah1, Necibe Fusun Oyman Serteller, Vedat Topuz Modeling and Simulation of Faulty Induction Motor in DQ Reference Frame Using MATLAB/SIMULINK with MATLAB/GUIDE for Educational Purpose March 2023 International Journal of Education and Information Technologies 17:7-20 DOI:10.46300/9109.2023.17.2
6. Mohammed M. A., Khaleel S. A., Al-Tameemi H. A. A. Fault Diagnosis on Induction Motor using Machine Learning and Signal Processing [Електронний ресурс] // arXiv. 2024. – Режим доступу: <https://arxiv.org/html/2401.15417v1>. – Дата звернення: 20.07.2025.
7. synthesizeTabularData - Synthesize tabular data [Електронний ресурс] // MATLAB - MathWorks. – Режим доступу: <https://www.mathworks.com/help/stats/synthesizetabulardata.html>. – Дата звернення: 29.07.2025.

8. Generate Synthetic Signals Using Conditional GAN [Електронний ресурс] // MATLAB & Simulink - MathWorks. – Режим доступу: <https://www.mathworks.com/help/deeplearning/ug/generate-synthetic-pump-signals-using-conditional-generative-adversarial-network.html>. – Дата звернення: 29.07.2025.

9. Saraa Ali, Aleksandr Khizhik, Stepan Svirin, Artem Ryzhikov, Denis Derkach. Learning to Hear Broken Motors: Signature-Guided Data Augmentation for Induction-Motor Diagnostics // arXiv. June 2025. <https://doi.org/10.48550/arXiv.2506.08412>

10. Hamming window [Електронний ресурс] // MATLAB - MathWorks. – Режим доступу: <https://www.mathworks.com/help/signal/ref/hamming.html>. – Дата звернення: 29.07.2025.

11. How to apply Hamming Window and compute FFT? [Електронний ресурс] // Signal Processing Stack Exchange. 2018. – Режим доступу: <https://dsp.stackexchange.com/questions/47702/how-to-apply-hamming-window-and-compute-fft>. – Дата звернення: 29.07.2025.

12. Goodfellow I., Bengio Y., Courville A. Deep Learning. Cambridge, Massachusetts : MIT Press, 2016. 800 с.

13. Example Deep Learning Networks Architectures [Електронний ресурс] // MATLAB & Simulink - MathWorks. – Режим доступу: <https://www.mathworks.com/help/deeplearning/ug/example-deep-learning-networks.html>. – Дата звернення: 29.07.2025.

14. Deep Learning Toolbox Documentation [Електронний ресурс] // MathWorks. – Режим доступу: <https://www.mathworks.com/help/deeplearning/index.html>. – Дата звернення: 29.07.2025.

15. Ананьєва О. М., Бабаєв М. М., Давиденко М. Г., Панченко В. В. Частотна локалізація та оцінювання параметрів сигналу тестування обмотки статора трифазного асинхронного двигуна. Інформаційно-керуючі системи на залізничному транспорті. 2023. № 4. С. 28-37.

16. Ананьєва О. М., Бабаєв М. М., Давиденко М. Г., Панченко В. В. Оцінювання параметрів неперервного зондуючого сигналу при тестуванні обмотки статора трифазного асинхронного двигуна Інформаційно-керуючі системи на залізничному транспорті. 2024. № 2. С. 52-60.

Прилипко Андрій Андрійович, доцент кафедри автоматики та комп'ютерного телекерування рухом поїздів, кандидат технічних наук, Український державний університет залізничного транспорту, Харків, Україна. ORCID iD: <https://orcid.org/0000-0001-6126-1085>. Тел.: +38(057) 730-10-32. E-mail: prilipkooa@kart.edu.ua.

Сосунів Олександр Олексійович, доцент кафедри автоматики та комп'ютерного телекерування

рухом поїздів, кандидат технічних наук, Український державний університет залізничного транспорту, Харків, Україна. ORCID iD: <https://orcid.org/0000-0003-2175-7363>. Тел.: +38(068) 607-88-13. E-mail: sosunov63@kart.edu.ua.

Змій Сергій Олексійович, доцент кафедри автоматики та комп'ютерного телекерування рухом поїздів, кандидат технічних наук, Український державний університет залізничного транспорту, Харків, Україна. e-mail: zmii.sergii@kart.edu.ua <https://orcid.org/0000-0002-7974-5181> Scopus Author ID: 57192821601

Щебликіна Олена Вікторівна, доцент кафедри автоматики та комп'ютерного телекерування рухом поїздів, PhD, Український державний університет залізничного транспорту, Український державний університет залізничного транспорту, Харків, Україна. e-mail: sov@kart.edu.ua ORCID: <https://orcid.org/0000-0002-8304-2921> Scopus Author ID: 57203618885

Prylypko Andrii, Associate Professor of the Department of Automation and Computerized Train Control, Cand. tech. Sciences, Ukrainian State University of Railway Transport. ORCID iD: <https://orcid.org/0000-0001-6126-1085>. Tel.: +38(057) 730-10-32. E-mail: prilipkooa@kart.edu.ua.

Sosunov Aleksandr, Associate Professor of the Department of Automation and Computerized Train Control, Cand. tech. Sciences, Ukrainian State University of Railway Transport. ORCID iD: <https://orcid.org/0000-0003-2175-7363>. Tel.: +38(068) 607-88-13. E-mail: sosunov63@kart.edu.ua.

Serhii Zmii, Associate Professor of the Department of Automation and Computerized Train Control, Cand. tech. Sciences, Ukrainian State University of Railway Transport, Kharkiv, Ukraine. e-mail: zmii.sergii@kart.edu.ua <https://orcid.org/0000-0002-7974-5181> Scopus Author ID: 57192821601

Olena Shcheblykina, Associate Professor, Department of Automation and Computerized Train Control, PhD, Ukrainian State University of Railway Transport, Ukrainian State University of Railway Transport, Kharkiv, Ukraine. e-mail: sov@kart.edu.ua ORCID: <https://orcid.org/0000-0002-8304-2921> Scopus Author ID: 57203618885

Prylypko A., Sosunov A., Serhii Z, Shcheblykina O

Diagnostics of an asynchronous motor using tooth characteristic removal and data processing with

artificial intelligence

Abstract. This article presents an innovative approach to the diagnostics of asynchronous motors (AMs), which are pivotal components in industrial applications and railway transport systems, particularly in automation and train remote control systems. The proposed method is grounded in a comprehensive analysis of tooth ripple harmonics within the stator current spectrum, utilizing Motor Current Signature Analysis (MCSA). This technique facilitates real-time condition monitoring of the motor without requiring its operational shutdown, thereby ensuring continuous system functionality.

The paper meticulously details the methodology, commencing with the acquisition of stator current signals at a high sampling frequency, which must exceed twice the maximum tooth ripple harmonic frequency. This is followed by the extraction and normalization of tooth ripple harmonics, whose frequencies are inherently dependent on specific motor parameters, including the number of stator and rotor slots, the number of pole pairs, and the supply frequency. A significant emphasis is placed on the precise identification of characteristic frequencies associated with various fault types, such as static and dynamic air-gap eccentricity, winding faults, and general mechanical defects.

A central tenet of the proposed diagnostic system is the integration of Artificial Intelligence (AI), specifically a multi-layer perceptron (MLP) feedforward neural network, for the automated processing and classification of the derived spectral data. The input layer of this neural network is designed to receive a comprehensive feature vector, comprising the normalized amplitudes of relevant tooth ripple harmonics and sideband frequencies. The network undergoes training using the backpropagation algorithm, coupled with a cross-entropy loss function to optimize its performance. Hidden layers employ the ReLU activation function, ensuring efficient learning and non-linearity, while the

output layer utilizes a Softmax function to classify the motor's operational state into four primary categories: normal operation, static eccentricity, dynamic eccentricity, and winding faults.

The presented simulation results, conducted on a 5.5 kW asynchronous motor with specific parameters ($p=2$, $N_r=28$, $f_1=50$ Hz), decisively corroborate the efficacy of the proposed methodology. Experiments encompassed the simulation of normal operating conditions, static eccentricity (simulated as a 0.3 mm displacement), and dynamic eccentricity (simulated as a 0.2 mm shaft bend). These simulations robustly demonstrated a significant increase in the amplitudes of characteristic harmonics at specific frequencies (e.g., 350 Hz and 650 Hz) when faults were introduced, thereby providing clear diagnostic indicators. The neural network, rigorously trained on a dataset of 1000 spectral samples, achieved a commendable classification accuracy of 94% on the unseen test set, validating its robust diagnostic capabilities.

The advocated diagnostic method not only substantially enhances diagnostic precision but also ensures operational efficiency, which is paramount for predictive maintenance, reducing operational costs, and extending the service life of critical equipment within the demanding environment of continuous railway transport system operations. While acknowledging the method's sensitivity to precise motor parameter definition and signal noise, future work is planned to integrate additional diagnostic features, such as vibration and temperature data, to further augment the system's accuracy and reliability, ensuring a more comprehensive diagnostic solution.

Keywords: Asynchronous motor, diagnostics, tooth ripple harmonics, spectral analysis, Motor Current Signature Analysis (MCSA), artificial intelligence, neural network, air-gap eccentricity, winding faults, predictive maintenance.