

Діагностика та прогнозне обслуговування індустриальних електродвигунів

Христина Висоцька¹, Віталій Павлюк², Адріан Наконечний³, Михайло Веселовський⁴

¹ студентка магістратури, Національний університет «Львівська політехніка», вул. Степана Бандери, 12, 79013, Львів, e-mail: khrystynavysotska@gmail.com

² студент магістратури, Національний університет «Львівська політехніка», вул. Степана Бандери, 12, 79013, Львів, e-mail: vpavliy3@gmail.com

³ д.т.н., професор, Національний університет «Львівська політехніка», вул. Степана Бандери, 12, 79013, Львів, e-mail: adrnakon@gmail.com

⁴ асистент, Національний університет «Львівська політехніка», вул. Степана Бандери, 12, 79013, Львів, e-mail: michael@veselovski.co.uk

На даний час перспективними методами діагностування електродвигунів на виробництвах є системи, що використовують засоби автоматичного постійного або періодичного контролю, спрямовані на прогнозування поломок та залишкового ресурсу двигунів. Однак більшість напрацьовань у даному напрямку залишаються суто теоретичними і часто досліджують дуже вузьку проблему або ж, навпаки, надають надто поверхневий огляд можливих методів та алгоритмів, тоді як в реальних умовах все ще використовуються в основному прилади ручного контролю і лише зрідка частково автоматизовані пристрої [1]. З огляду на це існує велика зацікавленість у розробленні програмного методу прогнозного обслуговування електродвигунів. У цьому дослідженні розглядаються рекурентні нейронні мережі з шарами довготривалої короткочасної пам'яті (ДКЧП-шарами), які здатні ефективно моделювати послідовні дані та вивчати складні залежності [2].

Ключові слова: діагностика електродвигунів, рекурентні нейронні мережі, прогнозування, класифікація поломок електродвигунів.

Вступ. Відомо, що електродвигуни споживають 70% всієї електроенергії, яка використовується промисловістю в світі. Виникнення непередбаченої поломки навіть в одного двигуна викликає незапланований простій та значні фінансові збитки для промислового виробництва. Зазвичай цю проблему вирішують плановими зупинками, проте не завжди потрібно проводити ремонт або замінювати компоненти, які ще можуть повністю функціонувати, що в свою чергу також призводить до непотрібних витрат.

Ринок електродвигунів в Україні вивчався компанією Pro-Consulting в період 2010-2020 років. Так моніторинг ринку електродвигунів, генераторів і редукторів в Україні вказує на зростаючу динаміку капітальних інвестицій в машини і обладнання в періоди 2010-2013 і 2016-2019 років. Деякий спад у 2014-2015 роках пояснюється найгострішою суспільно-політичною, економічною та військовою кризою в країні, а падіння 2020 року відбулося через карантинні обмеження, введені для боротьби з COVID-19. Близько 70% інвестицій в машини, обладнання та інвентар в досліджуваній період витрачені на придбання нових активів. [1].

Американський фінансовий аналітик Блейк Гріффін (експерт із систем автоматизації та промислової цифровізації) досліджуючи вплив повномасштабного вторгнення на електроенергетичний сектор, прийшов до висновку, що ринок електродвигунів вже зазнав значного зростання цін протягом 2021-2022 року в результаті підвищення цін на сировину (алюміній, мідний дріт тощо). Найбільш ймовірно, що ціни продовжуватимуть зростати і впродовж 2023 року [3].



Джерело: За даними Державної служби статистики України, оцінка Pro-Consulting

Рис.1. Динаміка капітальних інвестицій в машини, обладнання та інвентар в Україні в 2010-2020 рр., в млрд доларів США

Як наслідок, заміна електродвигунів чи їх компонентів під час планової діагностики, які ще придатні для експлуатації, з метою запобігання поломок, стає ще більш збитковою для виробництв порівняно з минулими роками. Тому вкрай актуальним представляє дослідження методів діагностики електродвигунів, що дозволили б вчасно передбачити ймовірну причину поломок електродвигунів та час до виходу з ладу, не зупиняючи процес виробництва і даючи змогу прийняття необхідних заходів для продовження життя моторів або заміни в них компонентів, якщо це дійсно необхідно.

Такий підхід відповідає прогнозованому обслуговуванню і вже відмінно зарекомендував себе на практиці у різних галузях в цілому світі. Так, за даними IoTAnalyticsResearch 2021 та PolarisMarketResearchAnalysis ринок прогнозного обслуговування зростає експоненціально: у 2016 році становив 1.5 мільярдів доларів США, у 2021 - 6.9 мільярдів доларів США, а вже у 2026 році оцінюють розмір ринку у 28.2 мільярдів доларів США [4, 5]. Дані Міністерства енергетики США свідчать, що прогнозне обслуговування є дуже економічно ефективним і допомагає підприємству досягати значних результатів таких як десятикратне збільшення рентабельності інвестицій, 70-75% зниження поломок, 25-30% зниження витрат та 35-45% зниження часу простою.

1. Мета і завдання дослідження

Мета представленої роботи полягає у використанні прогнозного обслуговування для сучасної діагностики електродвигунів шляхом програмного

підходу побудови рекурентної нейронної мережі. Розглядається побудова оптимізованої архітектури запропонованої нейронної мережі для вирішення завдань діагностики електродвигунів різної складності: бінарна класифікація (виявлення поломки), мультикласова класифікація (передбачення ймовірності конкретної поломки) та прогнозування залишкового ресурсу електродвигуна; експериментальне практичне випробування побудованої рекурентної нейронної мережі на реальних даних нормальної та аномальної роботи електродвигуна, аналіз результатів; інтеграція отриманої нейронної мережі у комплексну автоматичну систему діагностики електродвигуна.

Нові підходи, які розглядаються в роботі передбачають застосування рекурентних нейронних мереж, які здатні ефективно моделювати послідовні дані та вивчати складні залежності, для вирішення проблеми прогнозного обслуговування електродвигунів, а також інтегрувати ці мережі у єдину автоматичну комплексну систему діагностики. Одержані практичні результати застосування рекурентних нейронних мереж підтверджують успішність запропонованого підходу. Так, зокрема, проста нейронна мережа - бінарний класифікатор, - яка розроблена для потенційного впровадження локальних обчислень на кінцевих пристроях, продемонструвала точність 96% на раніше небачених даних, а дещо складніша мережа мультикласового класифікатора досягла точності 91% при розпізнаванні шести типів поломок. Отримані дані свідчать про високу здатність рекурентних нейронних мереж з шарами довготривалої короткочасної пам'яті (ДКЧП) ефективно розпізнавати та класифікувати стани електродвигунів на основі вібраційних даних.

2. Класифікація несправностей електродвигунів

Ефективна діагностика електродвигунів є надзвичайно критичною для забезпечення безперебійної роботи різноманітних систем та зниження витрат на обслуговування та ремонт. Сьогодні існує значна кількість методів та алгоритмів діагностики електродвигунів, які базуються на різноманітних підходах, включаючи аналітичні, статистичні, фізичні та інтелектуальні.

На даний час можна виділити такі чотири основні напрямки технічного обслуговування: експлуатація до відмови (run-to-failure), періодична планова діагностика (превентивне обслуговування), моніторинг стану (condition-based maintenance) та прогнозне обслуговування.



Рис.2.Класифікація підходів до технічного обслуговування моторів

Експлуатація до відмови. Підхід "експлуатація до відмови" виконується безпосередньо після виходу з ладу мотора, і, таким чином, це найпростіший, але водночас найдорожчий підхід серед інших [6]. Допуск критичних поломок мотора серйозно впливає на продуктивність і вартість виробничого процесу і часто призводить до неочікуваного та довготривалого часу простою через ресурсозатратний період обслуговування.

Періодична планова діагностика. Найбільш поширеним на практиці підходом до діагностики моторів завдяки своїй доступності та перевірності є ручна періодична планова діагностика електродвигунів. Періодичне тестування передбачає проведення запланованих перевірок і випробувань через заздалегідь визначені проміжки часу для оцінки справності двигуна. Такі випробування зазвичай виконуються за допомогою ручних пристроїв під час планових відключень на технічне обслуговування. Основна мета полягає в тому, щоб виявити будь-які існуючі проблеми та забезпечити безперервну експлуатаційну надійність двигуна.

Ручне періодичне діагностування, характеризується набором параметрів діагностування, а саме радіальне переміщення валу, рівень шуму, вібрація електродвигуна, температура підшипників, опір обмоток постійному струмові, несиметрія струмів у фазах обмоток статора, спотворення форми кривої струму.

Недоліком періодичної планової діагностики є те, що для її проведення часто потрібно призупиняти виробництво на тривалій період, що негативно впливає на продуктивність підприємства та призводить до значних фінансових втрат. Більш того, поломки можуть виникати несподівано, що призводить до ще більшої шкоди для виробничого процесу. Тому сучасні дослідження спрямовані на пошук методів для автоматизації діагностування та своєчасного виявлення несправностей.

Моніторинг стану. Сьогодні широкого застосування набувають пристрої для діагностування електрообладнання, які здійснюють постійний або періодичний автоматичний контроль за технічним станом електродвигуна в процесі його експлуатації [2]. Мета полягає в тому, щоб вчасно виявляти будь-які відхилення від нормальних робочих умов та сигналізувати про настання передаварійного стану, дозволяючи персоналу вжити відповідних заходів для запобігання виходу з ладу мотора. Методи моніторингу стану включають [7; 8]: онлайн-моніторинг вібрацій [9] та температурних режимів роботи двигуна, аналіз спектра струму двигуна.

Наступне прогнозне обслуговування розрізняють за наявністю подальшого інтелектуального аналізу даних, тоді як методи моніторингу стану виконують лише базову обробку даних, а подальше прийняття рішення покладається на експерта, що є ресурсозатратним і не гарантує виявлення помилки вчасно.

Прогнозне обслуговування. Таке обслуговування має на меті прогнозування технічного стану електромотора, що є достатньо складним завданням, скоротити трудомісткість і вартість робіт при поточних ремонтах, зекономити час при підготовці необхідного обладнання для діагностування, запланувати терміни ремонтних робіт або, за потреби, заздалегідь замінити електрообладнання [2]. Виходячи з цього більшість сучасних досліджень базуються саме на ідеї прогнозного обслуговування.

Методичні моделі прогнозування поломок електродвигунів та їх залишкового ресурсу можна розділити на такі категорії: моделі на основі знань, фізичні моделі, моделі на основі даних і моделі глибокого навчання. У моделях, заснованих на

знаннях, визначаються набори правил і оцінюються стани обладнання на основі попередніх несправностей, протевони іноді призводять до протиріч [10]. Фізичні моделі моделюють повне обладнання, однак це дорогийнапрямок і не завжди доступний.

На даний час проводяться дослідження великої кількості методів машинного навчання і, зокрема, глибокого навчання, з них можна виділити кілька найбільш поширених:

- *дерева рішень*: метод діагностики, який не потребує багато обчислювальних потужностей, має просту структуру і може працювати навіть з необробленими даними; водночас цей метод машинного навчання схильний до перенавчання, а саме навчання займає більше часу у порівнянні з іншими традиційними методами діагностики;

- *опорні векторні машини (ОВМ)*: за даним методом можливість працювати великимирозмірностями, з нелінійними процесами і невеликою обчислювальною потужністю, не вимагаєтьсяспецифікація даних, однак для даного випадку відсутня можливість фільтрації непотрібної інформації, складне управління, ризик перекриття векторів;

- *штучні нейронні мережі (ШНМ)*: даний метод є найбільш сучасним напрямком діагностики, адже дозволяєвирішувати практично будь-якізадачі, швидко навчається і є нечутливим до шуму, однак деякі недоліки все ж для нього присутні, а саме: схильність до перенавчання через складну структуру або недонавчання, феномен "чорної коробки", необхідність величезної кількості даних для навчання, яку часто важко зібрати і розмітити, необхідність великих обчислювальних потужностей для навчання тощо.

- *нечітка логіка*: перевагами даного методу є проста структура і гнучкий алгоритм, відсутність вимог до серверів та легке програмування, однак неточні дані або недостатня кількість даних призводять до поганих результатів.

Необхідно відзначити, що останні дослідження в даній області спрямовані на використанні нейронних мереж для діагностики несправностей електродвигунів, при цьому наводяться цікаві результати, які свідчать про перспективу розвитку даного методу [11; 12]. Нейронні мережі показали кращі результати діагностування завдяки своїм потужним і комплексним можливостям вилучення ознак і запам'ятовування залежностей. Структури та алгоритми навчання нейронних мереж постійно розробляються і покращуються, однак на даному етапі досліджень найбільш вивченими мережами, що демонструють перспективні результати при діагностиці, є: глибинні мережі переконань (ГМП) [12;13; 14], автокодери (АК) [15; 16], згорткові нейронні мережі (ЗНМ) [17;18] та рекурентні нейронні мережі (РНМ) [19; 20; 21].

3. Основні структури та алгоритми навчання нейронних мереж для діагностування моторів

3.1. Глибинні мережі переконань як метод діагностики моторів. Глибинні мережі переконань (ГМП) широко застосовуються у завданнях комп'ютерного зору, тому дослідження застосування таких мереж для рішення виявлення несправностей електродвигунів є нестандартним, але водночас цікавим методом з точки зору результатів. Вперше підхід до діагностики відмов двигунів (а саме авіаційних

двигунів) на основі ГМП був запропонований у 2013 році. Тут ГМП використовується як класифікатор для досягнення класифікації несправностей, при цьому вилучення ознак на основі ГМП не реалізовано. Також ГМП була описана як метод для діагностики несправностей компресора в 2014 році, тим самим підтверджуючи доцільність використання ГМП в секторі діагностики несправностей [14]. Ще один варіант реалізації діагностики електродвигунів на основі ГМП передбачає фіксацію сигналів частотної області від обертових механізмів, подачу їх на модель для виділення ознак і подальшої класифікації та визначення рівня несправності [12]. Автор також використав традиційну модель ГМП і опорно-векторні машини (ОВМ) для класифікації того самого сигналу та провів випробування, щоб показати, що оптимізована модель ГМП має найвищу точність класифікації серед трьох підходів (оптимізована модель ГМП > традиційна ГМП > ОВМ). ГМП мережа також була використана для діагностики несправностей вітряних турбін [22]. Водночас автор порівняв модель ГМП з класифікацією Байєса, класифікацією випадкового лісу, алгоритмом К-найближчих сусідів та деревами рішень, чотирма стандартними діагностичними підходами, та використав тести, щоб показати, що метод діагностики на основі ГМП є більш надійним і стабільним.

Однак, метод діагностування на основі ГМП має деякі недоліки. ГМП використовує метод напів контролюваного навчання, у якому кожен елемент, реалізований як обмежена машина Больцмана (ОМБ), навчається окремо, а параметри коригуються пошарово. У результаті навчання буде набагато повільнішим, ніж у традиційних методах діагностики дефектів, а поганий вибір параметрів призведе до зближення навчання до локального оптимуму.

3.2. Діагностування моторів на основі автокодерів. Автокодерам (АК) у порівнянні з ГМП достатньо меншої вибірки даних для тренування, а вилучення ознак даних є більш гнучким. До неглибоких мереж належать традиційна мережа автокодування, а також мережа розрідженого автокодування та мережа автокодування з усуненням шуму. На практиці вони часто об'єднуються в потужну глибоку мережу автокодування. Глибока розріджена самокодуюча мережа використовується в літературі [23] для виявлення дефекту міжвиткового короткого замикання синхронного двигуна з постійним магнітом, і дає точність класифікації 99,4%. В інших дослідженнях запропоновано багатопарову мережу автоматичного кодування з шумозаглушенням для діагностики несправності коробки передач вітрової турбіни, оскільки вібраційний сигнал містить багато шуму [24]. У наведеному експерименті мережа була натренована даними з різними рівнями шуму, що дозволило їй вивчити більш детальні та загальні характеристики несправностей з вібраційного сигналу. Рівень точності отриманої моделі варіювався від 97,5% до 98%. Для діагностики несправностей підшипників у деяких дослідженнях пропонується мережа глибокого автокодування [25]. Щоб покращити усунення шумів, мінімізувати обчислювальну складність і швидкість конвергенції навчання, автори інтегрують розріджену мережу автокодування з мережею автокодування із усуненням шуму, що є більш надійним методом і підвищує точність діагностики несправності підшипників кочення. Відсоток точності класифікації становить 99,68%.

Однак, звичайно, автокодери також відомі деякими недоліками. Зокрема, вихідні та вхідні дані звичайного автокодера ідентичні, що робить його схильним до перенавчання, яке можна уникнути певною мірою, якщо розмірність прихованого шару автокодера менша за розмірність вхідних даних, але це обмежує характеристики, які автокодер може представляти. Натомість, глибока мережа автокодування може вилучати більше корисних ознак, що однак призводить до значного сповільнення часу навчання.

3.3. Згорткові нейронні мережі як метод діагностики моторів. Згорткові нейронні мережі (ЗНМ) найчастіше застосовуються для аналізу візуальних зображень і відомі тим, що вимагають лише мінімальну попередню обробку сигналу. Згортковим нейронним мережам властива архітектура спільних ваг, тривимірних емностей нейронів та локального з'єднання, що дозволяє ефективно працювати зі зображеннями вищих роздільностей, зменшувати кількість параметрів мережі та запобігати перенавчання мережі, водночас знижуючи вимоги до пам'яті для роботи мережі та уможливаючи створення потужніших мереж [26].

На даному етапі досліджень, типи несправностей, які згорткова нейронна мережа може ідентифікувати, потребують подальших експериментів. Підходи згорткових нейронних мереж, які використовуються в області діагностики несправностей електродвигунів, можна розділити на два типи на основі існуючої літератури. Одним із методів є використання згорткових нейронних мереж як класифікатора [18]. Інший варіант полягає в тому, щоб використовувати згорткову нейронну мережу як модель вилучення ознак і розпізнавання [17] і класифікувати, застосовуючи адаптивне навчання ознак.

Цікавим напрямом дослідження є метод комплексної діагностики несправностей на основі згорткових нейронних мереж глибокого розпарування, який усуває обмеження традиційних методів діагностики (наприклад, відсутність урахування зв'язку між окремою несправністю та складними дефектами, оскільки традиційні класифікатори можуть виводити лише одне значення для вхідного набору тощо) [27]. По-перше, одновимірні глибокі згорткові нейронні мережі використовуються як модель навчання ознак, яка може ефективно вивчати дискримінаційні ознаки з необроблених вібраційних сигналів. По-друге, багатокомпонентні капсули розроблені як роз'єднувальний класифікатор для точної ідентифікації та роз'єднання складної несправності [27].

Тим не менш, реалізація згорткових нейронних мереж є відносно складною, і навчання згорткових нейронних мереж вимагає великої кількості даних, що також призводить до дуже низької швидкості навчання згорткових нейронних мереж. Через різницю між зображеннями та промисловими сигналами ефект згорткових нейронних мереж у промислових застосуваннях є не дуже задовільним. Тому існує відносно мало досліджень щодо застосування згорткових нейронних мереж у діагностиці несправностей мотора.

3.4. Діагностування моторів на основі рекурентних нейронних мереж. Рекурентна нейронна мережа (РНМ) — це модель нейронної мережі, яка чудово підходить для обробки послідовностей даних і відома швидкою конвергенцією, високою точністю та високою стабільністю. З точки зору діагностики дефектів, РНМ

особливо добре підходить для складного обладнання або систем. Типова РНМ має проблему експоненціального зростання або спадання градієнта, що заважає їй використовувати інформацію з минулого. Для вирішення даної проблеми використовується нейронна мережа довготривалої короткочасної пам'яті (ДКЧП), яка є стабільною і усуває проблему типових рекурентних нейронних мереж. ДКЧП широко використовується в області діагностики несправностей [28]. У дослідженні [28] ознаки вібраційного сигналу підшипника кочення вітрової турбіни виділяються за допомогою вейвлет-пакетного перетворення, а ДКЧП використовується як класифікатор для діагностики трьох найчастіших проблем підшипника кочення вітрової турбіни. У порівнянні з алгоритмом ОВМ було виявлено, що ДКЧП має вищий рівень точності. На даному етапі, усі літературні джерела використовують мережі ДКЧП як класифікатори, які повинні поєднуватися з іншими методами вилучення ознак, але також використовують адаптивне вилучення та класифікацію ознак ДКЧП, що не вимагає використання інших методів вилучення ознак або класифікатори.

4. Інтеграція нейронних мереж у цілісну систему

Щоб система мала змогу вирішувати завдання безпечної передачі даних, автоматичного прийняття рішень та інші, потрібно продумати та реалізувати низку пайплайнів - ланцюгів обробки даних, що є комбінацією процесів витягу, трансформації, передачі, збереження та моніторингу даних. Запропоновані нейронні мережі як методи діагностики є основним етапом саме трансформації даних. Архітектура системи повинна відповідати наступним вимогам: забезпечення обробки даних в реальному часі з мінімальною затримкою між збором даних та отриманням інформації з них; забезпечення ефективної та безпечної передачі та збереження великого обсягу даних.

Для досягнення поставлених вимог система повинна включати технології управління кінцевими пристроями, що дозволить безпечно збирати і передавати з них інформацію в режимі реального або майже реального часу; технології попереднього очищення та підготовки даних, передачі даних на нейронну мережу та обробки результатів, які повертатиме нейронна мережа; технології відображення стану системи та оповіщення персоналу про прогнози щодо стану електрообладнання за потреби; технології збереження великих об'ємів даних в аналітичну базу даних та виконання аналітичних операцій над ними; а також технології логування та моніторингу, щоб слідкувати за здоров'ям та стабільністю даної системи.

Отже, прогнозне обслуговування електродвигунів з метою передбачення можливих несправностей є найбільш перспективним напрямком у галузі і налічує безліч публікацій та експериментів, які доводять чи спростовують ефективність того чи іншого методу. Проте більшість таких досліджень мають виключно теоретичний характер і часто обмежуються вивченням лише однієї вузької проблеми або ж, навпаки, мають суто оглядовий характер. Звідси випливає, що дослідження недостатньо конкретизовані та не вирішують всіх проблем, пов'язаних з діагностикою електродвигунів. Тому, з огляду на викладене, необхідно надати особливу увагу розробці комплексної системи прогнозного обслуговування

електродвигунів. Суттєвою частиною такої системи повинні бути нейронні мережі, які дозволять вирішувати такі важливі завдання, як оцінка працездатності електродвигуна та прогнозування причин відмови. Загальна система повинна забезпечувати швидку й безпечну роботу з даними, їх інтелектуальний аналіз та інформування кінцевих користувачів про результати прогнозування.

5. Методи та засоби прогнозування несправностей електродвигуна

Основними завданнями системи є виявлення та класифікація несправностей електродвигуна. Для досягнення мети пропонується використання двох нейронних мереж відповідно: бінарного класифікатора та мультикласового класифікатора. У даному дослідженні методом реалізації названих мереж вибрано рекурентні нейронні мережі, оскільки вони, на даний час, успішно зарекомендували себе при роботі з послідовностями, адже у порівнянні з іншими мережами, враховують тимчасові залежності між спостереженнями для отримання додаткової інформації про взаємозв'язки між даними.

Вимірювальною метрикою роботи двигуна у даному дослідженні є вібрації - один з широко використовуваних способів контролю стану машин. Вібрації характеризують переважну більшість вузлів мотора, в тому числі і найбільш критичних, а отже мають високу інформативність та ефективність. Вібраційні сигнали можуть бути зібрані за допомогою недорогих та компактних пристроїв, що полегшує їх впровадження в реальних умовах експлуатації, а також є неконтактними та неінвазивними, тобто не потрібно розбирати або зупиняти роботу електродвигуна для отримання даних.

У даному дослідженні було проведено декілька замірів вібрацій з експериментального стенду, що використовується для моделювання різних поломок та режимів роботи двигуна. Одним із компонентів стенду є невеликий вентилятор, що слугує об'єктом вимірювання і виступає в ролі моделі реального двигуна. На вентиляторі встановлено акселерометр. Для експерименту було зібрано дані протягом 100 мілісекунд з урахуванням частоти дискретизації 3200 Гц, тобто було отримано 320 вимірювань з кожної осі під час одного запису. Заміри здійснювались при моделюванні різних режимів роботи двигуна: нормальному та аномальному, зокрема, при розбалансуванні та механічному нестабільному встановленні.

На етапі виділення характеристик даних вібраційний сигнал був представлений у частотному домені, оскільки спектральний аналіз дозволяє виявити основні частоти коливань та їх амплітуди, що чітко вирізняють специфічні характеристики сигналу при різних режимах роботи двигуна (рисунок 3-4).




Рис.3. Спектр сигналів вібрацій моделі двигуна, отриманих в процесі дослідження, по трьох осях у нормальному режимі функціонування




Рис.4. Спектр сигналів вібрації моделі двигуна, отриманих в процесі дослідження, по трьох осях з навантажувачем на одній лопаті

5.1. Архітектура та модель нейронної мережі з довготривалою короткочасною пам'яттю. Базова структура рекурентної мережі наведена на

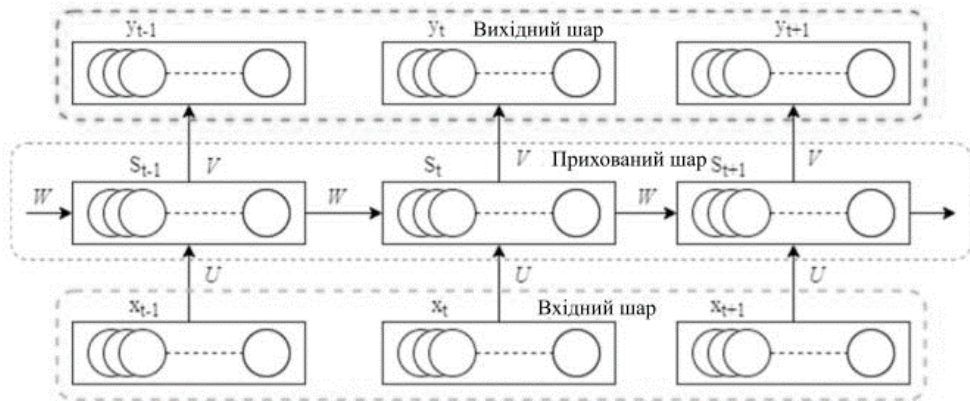


Рис.5. На діаграмі показано, що прихований шар не лише приймає вхідну інформацію у даний час t але й отримує вихід з прихованого шару за попередній час t-1, таким чином звертаючись до попередніх знань.




Рис.5. Базова архітектура рекурентної нейронної мережі

Математичну модель мережі можна описати рівняннями:

$$S_t = f(W S_{t-1} + U_{xt})$$

$$y_t = g(V S_t)$$

де:

- x_{t-1}, x_t, x_{t+1} - вхідні дані у момент часу t-1, t, t+1 відповідно;

- S_t, S_{t-1}, S_{t+1} - стан прихованого шару в момент часу $t-1, t, t+1$ відповідно;
- Y_{t-1}, Y_t, Y_{t+1} - вихідні дані у момент часу $t-1, t, t+1$ відповідно;
- f, g - функції активації;
- U - ваги зв'язків між вхідним і прихованим шаром;
- W - ваги зв'язків між прихованим шаром і прихованим шаром;
- V - ваги зв'язків між прихованим шаром і вихідним шаром.

Типова рекурентна нейронна мережа має складність, яка полягає в існуванні експоненціального зростання або спадання градієнта, що заважає їй використовувати інформацію з минулого [29]. Для вирішення даної задачі пропонується використання нейронної мережі з довготривалою короткочасною пам'ятю (ДКЧП), яка є стабільною і усуває проблему типових рекурентних нейронних мереж. ДКЧП-мережа складається з ДКЧП-модулів - рекурентних модулів мережі, які здатні запам'ятовувати значення як на короткі, так і на довгі проміжки часу. В основному це можливо за рахунок того, що ДКЧП-модулі не використовують функцію активації всередині своїх рекурентних компонентів [30].

ДКЧП-модулі часто групуються у блоки. Такий ДКЧП-блок містить три вентиля, які контролюють потік інформації на входах і виходах пам'яті блоку і вирішують, яка частина його пам'яті передається, а яка перезаписується. Вентилі реалізовані у вигляді логістичної функції для обчислення значень в діапазоні $[0;1]$. Множення сигналу на дане значення використовується для часткового допуску або заборони потоку на вході і виході пам'яті. Існують три різні вентиля:

1. вхідний вентиль ($i_c^{(t)}$);
2. вихідний вентиль ($o_c^{(t)}$);
3. вентиль забуття ($f_c^{(t)}$).

Вхідний вентиль контролює ступінь входження нового значення у пам'ять - вага отримання нової інформації. Вентиль забуття контролює ступінь збереження нового значення у пам'яті - вага запам'ятовування старої інформації. У деяких реалізаціях вхідний вентиль та вентиль забуття об'єднують в один, ідея якого полягає в тому, що попереднє значення забувається тоді, коли з'являється нове, варте запам'ятовування. Вихідний вентиль контролює те, в якій мірі значення, що знаходиться у пам'яті, використовується для розрахунку вихідної функції активації для блоку [30].

Ваги ДКЧП-блоку (W і U) використовуються для задання напрямку оперування вентилів і визначені для значень, які подаються в блок ($x^{(t)}$ - вхідний вектор та $h^{(t-1)}$ - попередній вихідний вектор) для кожного вентиля. Таким чином, ДКЧП-блок визначає, як розпоряджатись своєю пам'яттю, і навчання ДКЧП-мережі дозволяє ДКЧП-блоку визначити функцію, що мінімізує втрати. ДКЧП-мережу зазвичай навчають за допомогою методу зворотного поширення помилки [30].

Традиційну ДКЧП мережу можна описати наступними рівняннями [30]:

$$\begin{aligned}
 i^{(t)} &= \sigma(W_i \times x^{(t)} + U_i \times h^{(t-1)} + b_i) \\
 f^{(t)} &= \sigma(W_f \times x^{(t)} + U_f \times h^{(t-1)} + b_f) \\
 o^{(t)} &= \sigma(W_o \times x^{(t)} + U_o \times h^{(t-1)} + b_o) \\
 s^{(t)} &= s^{(t-1)} \odot f^{(t)} + i^{(t)} \odot \tanh(W_s \times x^{(t)} + U_s \times h^{(t-1)} + b_s)
 \end{aligned}$$

$$h^{(t)} = \tanh(s^{(t)}) \odot o^{(t)}$$

де:

- \odot - точкове множення,
- \times - матричне множення,
- $x^{(t)}$ - вхідний вектор,
- $h^{(t)}$ - вихідний вектор,
- $s^{(t)}$ - вектор станів,
- W, U, b - ваги ДКЧП-блоку, визначені для кожного вентиля для вхідного вектора та попереднього вихідного вектора, а також вектор зміщення,
- $f^{(t)}$ - вентиль забуття,
- $i^{(t)}$ - вхідний вентиль,
- $o^{(t)}$ - вихідний вентиль,
- σ - сигмоїдна функція активації,
- \tanh - функція активації на основі гіперболічного тангенса.




Рис.6. Архітектура ДКЧП-блоку

Для побудови нейронних мереж у даній роботі використовуються наступні засоби:

- *JupyterNotebook* - інтерактивне середовище для написання коду та тексту різними мовами програмування;
- *TensorFlow* - відкрита бібліотека для побудови, тренування та тестування моделей машинного навчання;
- *GoogleCloudVirtualMachines* - обчислювальні потужності для тренування та тестування мережі;
- *Matplotlib* - відкрита бібліотека на Python для візуалізації даних;

- *SciPy* - відкрита бібліотека математичних інструментів на Python;
- *Sklearn* - відкрита бібліотека на Python для обробки даних, а також побудови та тренування моделей машинного навчання.

5.2. Виявлення несправностей електродвигуна. Для виявлення несправностей електродвигуна, тобто ідентифікації аномалій у роботі електродвигуна на ранніх стадіях, що відрізняється від нормального стану, пропонується використання рекурентної нейронної мережі бінарного класифікатора.

Архітектура моделі бінарного класифікатора зображена на Рис.7. Вона складається з двох основних шарів: прихованого ДКЧП-шару зі 100 нейронами та вихідного шару прямого поширення з одним нейроном. У структурі можна також побачити два випадючі шари: між вхідним шаром та прихованим ДКЧП-шаром, між прихованим ДКЧП-шаром та вихідним шаром. Випадаючі шари - це простий та ефективний метод регуляції для нейронних мереж, які схильні до перенавчання.

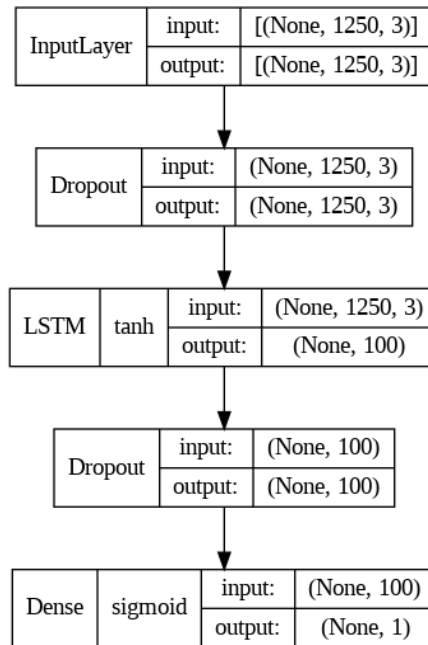


Рис.7. Архітектура нейронної мережі бінарного класифікатора

Вихідний шар використовує сигмоїдну функцію активації, яка повертає значення в межах від 0 до 1, що інтерпретується як ймовірність того, що двигун є несправним:

$$f(x) = \sigma(x) = \frac{1}{1 + e^{-x}}$$



Рис.8. Графік сигмоїдної функції активації

Для тренування мережі пропонується використати метод зворотного поширення помилки, структура якого наведена на Рис.9.

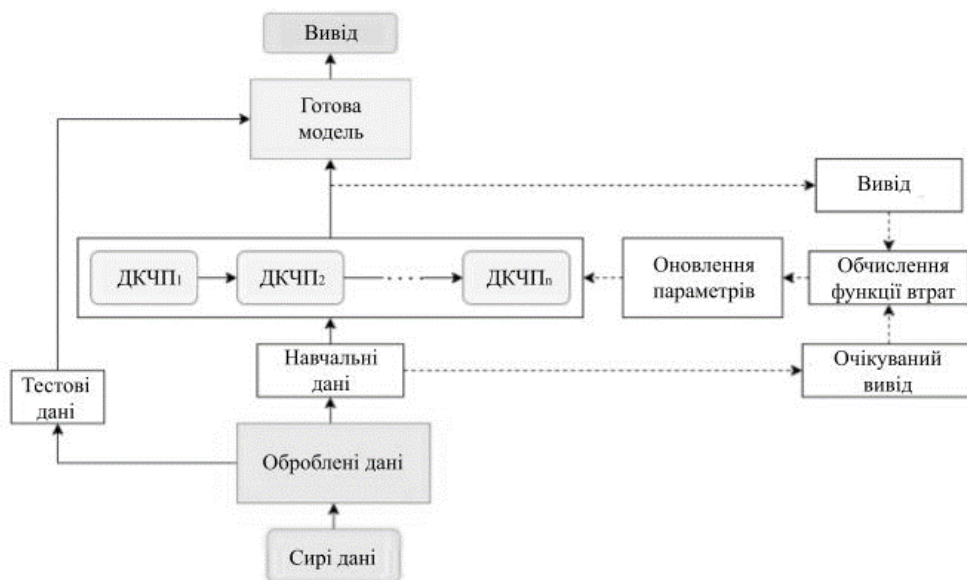


Рис.9. Тренування ДКЧП мережі за методом зворотного поширення помилки

Перед тренуванням необхідно задати функцію втрат, яка оцінює, наскільки добре працює нейронна мережа. Так, чим більший результат функції втрат, тим гірша робота нейронної мережі, а тренування спрямоване на мінімізацію результатів функції. Для даної задачі бінарної класифікації пропонується використати функцію втрат під назвою бінарна крос-ентропія:

$$H_p(q) = -\frac{1}{N} \sum_{i=1}^N y_i \cdot \log(p(y_i)) + (1 - y_i) \cdot \log(1 - p(y_i))$$

де y - очікуване передбачення (0 або 1), а $p(y)$ - отримане передбачення, у випадку даної системи це ймовірність того, що мотор несправний.

Під час тренування класифікатор на кожній епісі обчислює крос-ентропію між розподілом отриманих та очікуваних значень і намагається мінімізувати її. У формулі використовуються логарифми від ймовірностей, оскільки їх область значень є дуже зручною для функції втрат: на проміжку від 0 до 1 функція зростає (але у

формулі береться негативний логарифм, тому функція спадає), відтак чим менша отримана ймовірність правдивого значення, тим більшою є функція втрат.

При тренуванні слід задати спеціальну конфігурацію, при якій функція втрат обчислюється на кожній епосі не лише на навчальних даних, але й на контрольних даних, щоб ідентифікувати перенавчання, тобто коли результат на навчальних даних покращується, а на контрольних залишається однаковим або ж навіть погіршується. Як результат, зберігатиметься лише та версія мережі, при якій значення функції втрат на контрольному наборі даних була мінімальною.

5.3. Класифікація несправностей електродвигуна. Для класифікації несправностей електродвигуна, тобто визначення ймовірності розвитку кожної поломки з деякого набору поломок, пропонується використання мультикласового класифікатора на основі рекурентної нейронної мережі.

Архітектура моделі мультикласового класифікатора представлена на Рис.10. Вона складніша порівняно із архітектурою бінарного класифікатора, оскільки вирішує складнішу задачу, і складається з трьох основних шарів: прихованого ДКЧП-шару зі 200 нейронами, прихованого шару прямого поширення з 200 нейронами та вихідного шару прямого поширення з 7 нейронами (відповідно до кількості класів). У структурі знову ж таки спостерігається наявність випадючих шарів, які були введені з метою запобігання перенавчання мережі: між вхідним шаром та прихованим ДКЧП-шаром, між прихованим ДКЧП-шаром та прихованим шаром прямого поширення, між прихованим та вихідним шаром прямого поширення.

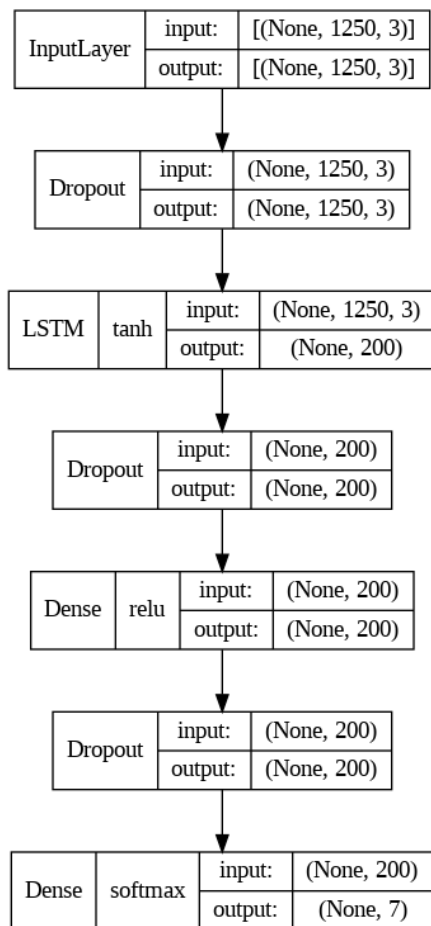


Рис.10. Архітектура нейронної мережі мультикласового класифікатора

Прихований шар прямого поширення використовує випрямлену лінійну функцію активації, яку рекомендується обирати як функцію активації за замовчуванням:

$$f(x) = \begin{cases} 0, & x < 0 \\ x, & x \geq 0 \end{cases}$$




Рис.11. Графік випрямленої лінійної функції активації

Вихідний шар мережі використовує нормовану експоненційну функцію активації, яка є функцією від декількох змінних і повертає вектор з невід'ємних значень, сума яких рівна одиниці. Кожне значення такого вектора можна

інтерпретувати як ймовірність приналежності вхідної послідовності даних до відповідного класу:

$$f_i(x) = \frac{e^{x_i}}{\sum_{j=1}^J e^{x_j}}, \text{ для } i = 1, \dots, J$$

Для тренування мультикласового класифікатора, як і у випадку бінарного класифікатора, використовується метод зворотного поширення помилки. Функцією втрат є також крос-ентропія, за винятком того, що для даної задачі це категорійна крос-ентропія, а не бінарна, оскільки кількість класів тепер більша, ніж два. При цьому розрізняють розріджену та нерозріджену категорійну крос-ентропію, які обидві працюють за однаковим алгоритмом, однак відрізняються форматом очікуваних вихідних значень. Так, при нерозрідженій категорійній крос-ентропії кожне очікуване значення повинне бути вектором, довжина якого рівна кількості класів, а елементами якого є лише 0 та 1, де індекс елемента l визначає очікуваний клас для даного спостереження. Така репрезентація має назву унітарний код. У випадку розрідженої категорійної крос-ентропії кожному спостереженню відповідає лише деяке число, а не вектор, що вказує на очікуваний клас. У даній роботі використовується розріджена категорійна крос-ентропія, оскільки її перевагою є економія пам'яті та часу обчислення.

Висновки. В роботі розглянуто методи розв'язання задачі виявлення та класифікації несправностей електродвигунів на основі рекурентних нейронних мереж (РНМ). Обґрунтовано переваги РНМ у даній системі, зокрема здатність до аналізу послідовностей даних та адаптації до змін у структурі даних. Запропоновано архітектуру нейронної мережі на основі ДКЧП-шарів, які дозволяють подолати проблему затухання градієнтів традиційних рекурентних нейронних мереж та покращити точність класифікації несправностей електродвигунів. Обґрунтовано вибір функцій активації, описаний процес тренування.

Література

1. Ринок електродвигунів, редукторів і генераторів в Україні: на порозі нової електрифікації. Аналіз ринку. Pro-Consulting. URL: <https://pro-consulting.ua/ua/pressroom/rynok-elektrodvigatelej-reduktorov-i-generatorov-v-ukraine-na-poroge-novoj-elektifikacii>.
2. Яцун А.М., Яцун М.А. Експлуатація та діагностування електричних машин і апаратів: Навч. посібник. - Львів: Видавництво Національного університету "Львівська політехніка", 2010. - 228 с.
3. Ukraine. How much does it weigh in the e-motor world? - Electric Motor Engineering. Electric Motor Engineering. URL: <https://www.electricmotorengineering.com/ukraine-how-much-does-it-weigh-in-the-e-motor-world/>.
4. Predictive Maintenance Market Size Global Report, 2022 - 2030. Polaris. URL: <https://www.polarismarketresearch.com/industry-analysis/predictive-maintenance-market>.
5. Predictive Maintenance Market: The Evolution from Niche Topic to High ROI Application. IoT Analytics. URL: <https://iot-analytics.com/predictive-maintenance-market-evolution-from-niche-topic-to-high-roi-application/>.
6. Salonen A., Deleryd M. Cost of poor maintenance. Journal of Quality in Maintenance Engineering. 2011. T.17, №1. С.63–73. URL: <https://doi.org/10.1108/13552511111116259>.
7. Holbert K.E., Lin K., Karady G.G. Enhancement of electric motor reliability through condition monitoring. IFAC Proceedings Volumes. 2006. T.39, №7. С.255–260. URL: <https://doi.org/10.3182/20060625-4-ca-2906.00049>.
8. Methods of Condition Monitoring and Fault Detection for Electrical Machines / K. Kudelina та ін. Energies. 2021. T.14, №22. С.7459. URL: <https://doi.org/10.3390/en14227459>.

9. Real time condition monitoring system for industrial motors / Goundar S. S. та ін. 2015 2nd Asia-Pacific World Congress on Computer Science and Engineering (APWC on CSE) (2–4 груд. 2015 р., м. Nadi, Fiji). Nadi, 2015. URL: <https://doi.org/10.1109/apwccse.2015.7476232>.
10. Hybrid reasoning for prognostic learning in CBM systems / A. K. Garga та ін. 2001 IEEE Aerospace Conference Proceedings, м. Big Sky, MT, USA. URL: <https://doi.org/10.1109/aero.2001.931316>.
11. Deep learning and its applications to machine health monitoring / Zhao R. та ін. Mechanical Systems and Signal Processing. 2019. Т.115. С.213–237. URL: <https://doi.org/10.1016/j.ymssp.2018.05.050>.
12. Improved Deep Belief Network and Model Interpretation Method for Power System Transient Stability Assessment / Wu S. та ін. Journal of Modern Power Systems and Clean Energy. 2020. Т.8, №1. С.27–37. URL: <https://doi.org/10.35833/mpce.2019.000058>.
13. Tamilselvan P., Wang P. Failure diagnosis using deep belief learning based health state classification. Reliability Engineering & System Safety. 2013. Т.115. С.124–135. URL: <https://doi.org/10.1016/j.res.2013.02.022>.
14. Tran V. T., AlThobiani F., Ball A. An approach to fault diagnosis of reciprocating compressor valves using Teager–Kaiser energy operator and deep belief networks. Expert Systems with Applications. 2014. Т.41, №9. С.4113–4122. URL: <https://doi.org/10.1016/j.eswa.2013.12.026>.
15. Discriminative Auto-Encoder With Local and Global Graph Embedding / Li R. та ін. IEEE Access. 2020. Т.8. С.28614–28623. URL: <https://doi.org/10.1109/access.2020.2972132>.
16. Relational autoencoder for feature extraction / Meng Q. та ін. International Joint Conference on Neural Networks (14–19 трав. 2017р., Anchorage, AK, USA). Anchorage, 2017. URL: <https://doi.org/10.1109/ijcnn.2017.7965877>.
17. Fault Diagnosis for Rotating Machinery Using Multiple Sensors and Convolutional Neural Networks / Xia M. та ін. IEEE/ASME Transactions on Mechatronics. 2018. Т.23, №1. С.101–110. URL: <https://doi.org/10.1109/tmech.2017.2728371>.
18. Gearbox Fault Identification and Classification with Convolutional Neural Networks / Chen Z. та ін. Shock and Vibration. 2015. Т.2015. С.1–10. URL: <https://doi.org/10.1155/2015/390134>.
19. Moustapha A. I., Selmic R. R. Wireless Sensor Network Modeling Using Modified Recurrent Neural Networks: Application to Fault Detection. IEEE Transactions on Instrumentation and Measurement. 2008. Т.57, №5. С. 981–988. URL: <https://doi.org/10.1109/tim.2007.913803>.
20. Recurrent neural network applied to fault diagnosis of Underwater Robots / Wang J. та ін. 2009 IEEE International Conference on Intelligent Computing and Intelligent Systems (ICIS 2009) (20–22 лист. 2009 р., Shanghai, China). Shanghai, 2009. URL: <https://doi.org/10.1109/icicisys.2009.5357773>.
21. Salem F. M. Network Architectures. Recurrent Neural Networks. 2021. С.3–19. URL: https://doi.org/10.1007/978-3-030-89929-5_1.
22. Early Fault Detection of Wind Turbines Based on Operational Condition Clustering and Optimized Deep Belief Network Modeling / Yang Y. та ін. Energies. 2019. Т.12, №6. С.984. URL: <https://doi.org/10.3390/en12060984>.
23. Diagnosis of Inter-turn Short Circuit of Permanent Magnet Synchronous Motor Based on Deep Learning and Small Fault Samples / Li Y. та ін. Neurocomputing. 2021. Т.442. С.348–358. URL: <https://doi.org/10.1016/j.neucom.2020.04.160>.
24. Stacked Multilevel-Denoising Autoencoders: A New Representation Learning Approach for Wind Turbine Gearbox Fault Diagnosis / Jiang G. та ін. IEEE Transactions on Instrumentation and Measurement. 2017. Т.66, №9. С. 2391–2402. URL: <https://doi.org/10.1109/tim.2017.2698738>.
25. Stacked Sparse Autoencoder-Based Deep Network for Fault Diagnosis of Rotating Machinery / Qi Y. та ін. IEEE Access. 2017. Т.5. С.15066–15079. URL: <https://doi.org/10.1109/access.2017.2728010>.
26. Deep Transfer Learning in Mechanical Intelligent Fault Diagnosis: Application and Challenge / Qian C. та ін. Neural Processing Letters. 2022. Т.54, С.2509–2521. URL: <https://doi.org/10.1007/s11063-021-10719-z>.
27. Deep Decoupling Convolutional Neural Network for Intelligent Compound Fault Diagnosis / R. Huang та ін. IEEE Access. 2019. Т.7. С.1848–1858. URL: <https://doi.org/10.1109/access.2018.2886343>.
28. Hou Z.R. Rolling Bearing Fault Diagnosis Based on Wavelet Packet and Improved BP Neural Network for Wind Turbines. Applied Mechanics and Materials. 2013. Т.347-350. С.117–120. URL: <https://doi.org/10.4028/www.scientific.net/amm.347-350.117>.
29. Bengio Y., Simard P., Frasconi P. Learning long-term dependencies with gradient descent is difficult. IEEE Transactions on Neural Networks. 1994. Т.5, №2. С.157–166. URL: <https://doi.org/10.1109/72.279181>.
30. Long short-term memory. Вікіпедія: Вільна Українська Енциклопедія (Wikipedia: The Free Encyclopedia). URL: <https://uk.wikipedia.org/wiki>.

Diagnosics and predictive maintenance of industrial electric motors

Khrystyna Vysotska, Vitalii Pavliuk, Adrian Nakonechnyi, Mykhailo Veselovskyi

Automatic continuous or periodic control is the most promising method of diagnosing electric motors in production nowadays. It is aimed at predicting breakdowns and the remaining useful lifetime of motors. However, research in this area remains purely theoretical and either focuses on very narrow problems or provides too superficial overview. Consequently, manual control devices or partially automated devices are mainly used in practice [1]. In view of this, there is great interest in the development of a software method for predictive maintenance of electric motors. In this research recurrent neural networks with long short-term memory layers (LSTM-layers) are investigated due to their ability to effectively model sequential data and learn complex dependencies [2].

Keywords: diagnostics of electric motors, recurrent neural networks, forecasting, classification of electric motor failures.

Отримано: 19.11.2023.