

УДК 004.891.3

Т. В. АЛТУХОВА
Індустріальний інститут
Державного вищого навчального закладу
«Донецький національний технічний університет»
tanyalt34@gmail.com

МЕТОДИ ДІАГНОСТИКИ ВІДМОВ ЕЛЕКТРОМЕХАНІЧНОГО ОБЛАДНАННЯ НА ОСНОВІ ТЕХНОЛОГІЙ ШТУЧНОГО ІНТЕЛЕКТУ

Анотація: В даній роботі розглянуто останні розробки та застосування штучного інтелекту для моніторингу стану та діагностики несправностей, відповідно до категорій діагностики несправностей. Проведено порівняльний аналіз характеристик обчислювальних методів діагностики, які можна розглядати при виборі відповідного методу в конкретній ситуації для майбутніх досліджень.

Ключові слова: електромеханічне обладнання, штучні нейронні мережі, генетичний алгоритм, нечітка логіка, глибока нейронна мережа, методи діагностики несправностей.

Актуальність проблеми. Економічна ситуація, що склалася в останні роки в енергетичній галузі нашої країни, вимагає приймання значних запобіжних заходів, які направлені на збільшення строків експлуатації різного електромеханічного обладнання, яке в свою чергу пов'язано із застосуванням ефективних методів діагностики [1]. Ефективний моніторинг стану дозволяє раннє виявлення несправностей з урахуванням простоти, витрат на технічне обслуговування, надійності роботи та ефективності виробництва. Дослідження моніторингу стану машин та діагностики несправностей є значним [2,3].

Сучасну діагностику електрообладнання умовно розподіляють на три основні напрямки, а саме параметрична діагностика, діагностика несправностей та превентивна діагностика [4]. Мета всіх трьох напрямків полягає у визначені причини виникнення аномалій та проведення необхідних заходів, щодо виходу з ладу, шляхом збору даних минулого та поточного стану обладнання, таких як вібрація, шум, температура, стан змащення та інше. Моніторинг електромеханічного обладнання складається з трьох етапів: виявлення ознак, діагностика несправностей і прогнозування [5]. Виявлення ознак та діагностика збоїв зазвичай необхідні для виявлення аномального стану, визначення місця знаходження дефектів та прогнозування ступеню відмов [6]. На рисунку 1 зображена умовна структурна схема діагностики для будь-якого типу та призначення обладнання, що характеризується теорією розпізнавання та теорією контролездатності [4].

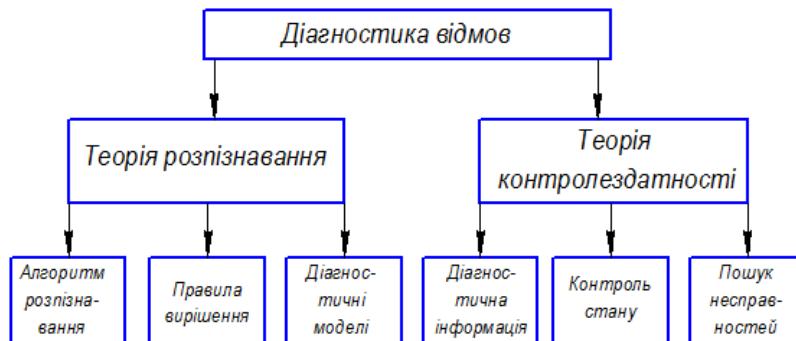


Рисунок 1 – Схема умовної структури діагностики відмов (за джерелом [4])

За останні декілька десятків років було запропоновано багато методів моніторингу стану машин та діагностики несправностей, що можна класифікувати за методами моделювання, статистики та використання штучного інтелекту [1]. Методи, що засновані на моделях, базуються на фізичних характеристиках досліджувемого об'єкту для створення явної математичної моделі, яка широко використовується в діагностуванні механічної частини. Але дані діагностичні методи на основі математичної моделі важко використовувати, так як важко описати точно модель системи в математичному вигляді. Статистичні моделі передбачають, що вихідні дані по дефектам можуть бути використані для представлення майбутніх відмов електромеханічного обладнання, але ми повинні розуміти, що характеристика відмов може змінюватися з часом. Тому статистичні методи не можуть повною мірою відобразити процес зносу, а особливо у випадку поетапного його розвитку [7]. На даний час для вирішення складних і масштабних нелінійних задач без будь-яких статистичних припущень щодо даних підходять технології штучного інтелекту [8].

Технології штучного інтелекту широко використовуються в науково-дослідницькій та інженерній практиці. Так, наприклад, прикладними програмами є перевірка якості [9], автоматичний контроль [10], медичні і біологічні [11], та екологічні [12]. Штучний інтелект імітує поведінку природи та людей шляхом використання комп'ютерних наук та технологій, тому його можна назвати інтелектуальним методом оптимізації. Даний метод може бути класифікований за трьома основними групами, а саме нейророзрахунки, еволюційні алгоритми та нечітке обчислення. В останні десятиліття саме інтелектуальним методам оптимізації приділялася значна увага [13]. Незважаючи на значні досягнення в даній області, було запропоновано декілька нових методів діагностики на базі штучного інтелекту, а саме нечітка нейронна мережа [14], глибока мережа навчання [15] та екстремальна машина навчання (ЕМН) для вирішення практичних проблем [16].

Аналіз попередніх досліджень. В існуючих джерелах інформації дані методи були досліджені в області хвильової енергії [17], фінансового ринку [18] та порушення якості електроенергії [19,20], але опубліковані оглядові статті про діагностику електромеханічного обладнання мають обмежену сферу. В роботах зосереджується увага на вилученні ознак дефектів обладнання [21] або на методах прогнозування механізмів обертання [22].

Тому **головна мета** даної наукової публікації – виконати аналіз існуючих методів діагностики відмов електромеханічного обладнання на базі технологій штучного інтелекту.

Основний матеріал дослідження. Діагностика несправностей, яка поєднує в собі механізм виявлення збоїв роботи обладнання та методи виявлення, заснована на теорії обробки сигналу та розпізнавання образів. Тому далі ми розглянемо різноманітні алгоритми на базі штучного інтелекту для моніторингу дефектів електромеханічного обладнання (ЕМО). На рисунку 2 зображена структурна схема методів на базі штучного інтелекту, які використовувалися в якості класифікаторів для діагностики несправностей ЕМО.

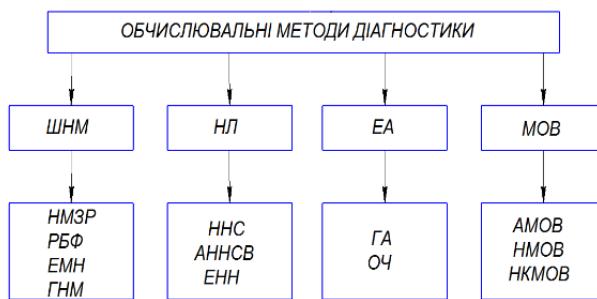


Рисунок 2 – Схема структури методів на базі штучного інтелекту для діагностики несправностей ЕМО

Розглянемо в першу чергу застосування штучних нейронних мереж (ШНМ), які є особливим випадком нейронних обчислень. ШНМ являють собою математичну модель, що дозволяє досягти розподіленої обробки паралельної інформації. Штучні нейронні мережі можуть регулювати взаємозв'язки між внутрішніми вузлами для досягнення інформаційної обробки складної системи.

Результати при діагностуванні несправностей можна інтерпретувати як вирішення проблем, заснованих на конкретному співвідношенні між ознаками несправностей та причиною їх виникнення. Для складних механічних систем цей взаємозв'язок відображення взагалі нелінійний. Тому дані методи на базі штучних нейронних мереж були використані в діагностіці збоїв ЕМО, оскільки можна ефективно наблизити різноманітні відносини відображення. На сьогоднішній день більшість методів класифікації несправностей використовують методи часто-часового аналізу як ранньої функції виявлення, а потім ШНМ або їх оптимізовані форми використовуються для визначення несправностей обладнання. На рисунку 3 зображена блок-схема діагностики несправностей на основі штучних нейронних мереж.

В публікації [23] вейвлет-перетворення та штучні нейронні мережі були застосовані для діагностування несправностей двигуна внутрішнього згорання, де вейвлет-перетворення застосовувалися для виявлення ознак несправностей, та запропонували узагальнювати повторювальну нейронну мережу для класифікації різноманітних умов виникнення помилок. В наступній статті [24] авторами було запропоновано метод інтелектуального діагностування, що ґрунтується на базі методу емпіричного розкладання (МЕР) та вейвлет-нейромережі. МЕР використовувалося для вилучення характеристик часових та частотних доменів з вбудованих функцій (ВФ), а вейвлет-нейромережі були необхідні для завершення розпізнавання образів. Вейвлет-перетворення та МЕР були використані для попередньої обробки та вилучення функцій, тоді як штучна нейронна мережа була використана для діагностики ранньої несправності в оберталючих механізмах обладнання [25]. Авторами публікації [26] було запропоновано нову нейронну мережу зворотнього розповсюдження (НМЗР) на основі ентропії пакетного розкладання невеликої хвилі для реалізації кількісної діагностики відмов підшипників кочення. В роботі [27] представили новий гібридний метод, який базується на дискретному велет-перетворенні (ДВП) та ШНМ для діагностики різних несправностей з зубчастої конічної коробки передач. Точний вибір відповідних функцій, які відображають стан роботи ЕМО в практичному застосуванні для діагностики несправностей, є важливим напрямом в області досліджень. Щодо діагностики відмов механічної системи на базі штучних нейронних мереж, то вони мають ряд обмежень, а саме створення і вибір функцій залежить значною мірою від попередніх знань технології обробки

сигналу та досвіду діагностування, а об'єднання слабке. ШНМ приймають неглибоку структуру, які також їх обмежують для вивчення складних нелінійних структур у діагностиці відмов [28]. Глибока нейронна мережа (ГНМ), що розроблена на базі глибокої теорії навчання, може підвищити точність більшої кількості даних [29] та ефективно подолати попередні недоліки. Вперше застосування ГНМ в діагностиці несправностей було висвітлено в роботі [30], де застосовано мережу глибоких переконань (МГП) на базі оператора енергії Тіджера для досягнення діагностики несправностей зворотних клапанів компресора. Авторами наступної праці [31] розроблена ієрархічна адаптивна глибококонвертуюча нейронна мережа для діагностики розладів. Ф. Цзя та інші автори [32] використовували МГП для діагностики несправностей в обертальному обладнанні, особливо в тому випадку, коли дані вібрації були більш масивними.

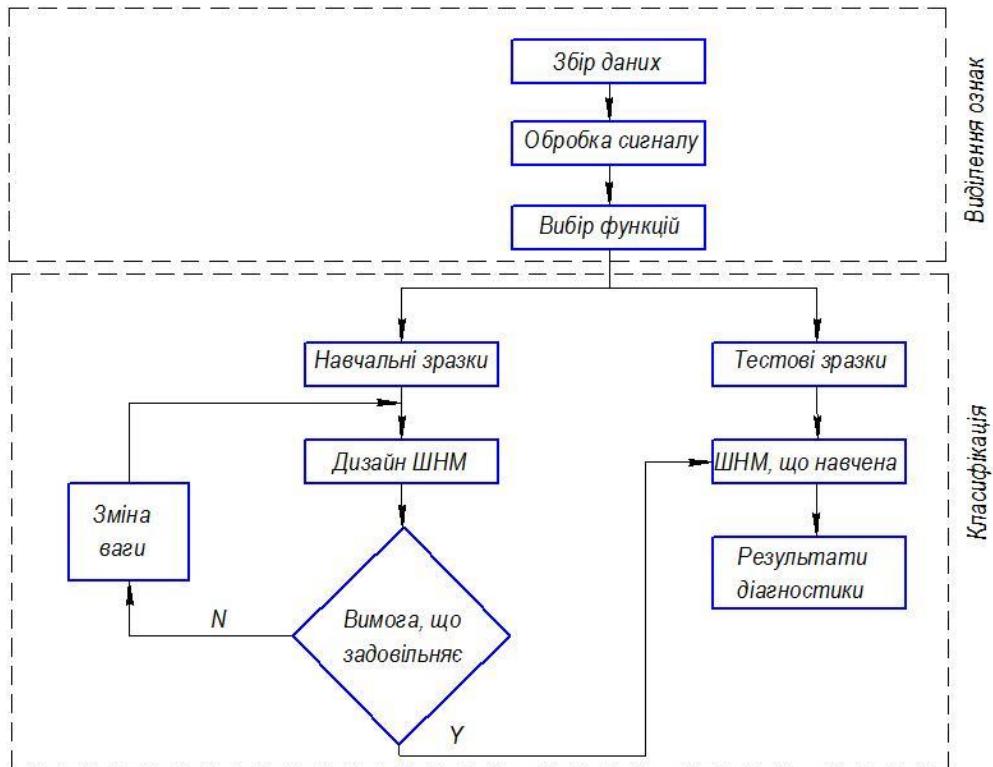


Рисунок 3 – Блок-схема діагностики несправностей ЕМО на основі ШНМ (за джерелом [28])

В останні роки ЕМО широко застосовується у діагностиці несправностей механічної системи. Автори роботи [33] запропонували багатошарову ЕМО, яка заснована на репрезентативному навчанні для діагностики відмов. Ефективність цього методу була успішно підтверджена за допомогою вітрової турбіни. Ю. Вей та інші розробники [34] запропонували метод, що базується на локальному середньому розкладі для виявлення різних типів несправностей коробки передач, що поєднує в собі ентропію перманентності та ЕМО.

Далі розглянемо застосування нечіткої логіки та нейро-нечіткіх систем (ННС) в діагностиці електромеханічного обладнання. Взаємозв'язок між помилками та ознаками несправностей достатньо важко описати, використовуючи точну математичну модель, через складність інженерної практики. Тому застосування на основі теорії нечіткої логіки в діагностиці несправностей зводиться до людського мислення та мовного вираження. Нечітка логіка (НЛ) є ефективним методом розпізнавання образів, що успішно використовується в енергетиці [35], лініях електропередач [36], транспорті [37] та промисловому виробництві [38]. НЛ в основному імітує логічне мислення людини і, таким чином, має сильну здатність вираження знання, а ШНМ імітує функцію людського нейронного мозку, який має сильну здатність самостійного навчання та безпосередньої обробки даних. Адаптивна нейро-нечітка система висновків (АННСВ) включає як переваги нейронної мережі, так і нечіткої логіки. Автори наукової праці [39] запропонували метод діагностики несправностей на загальному розкладанні та нечіткої ентропії (НЕ) для діагностики несправностей підшипників кочення. Ряди внутрішніх вузлів шкали (РВВШ) вперше одержали за допомогою РК-дисплея, а потім були вилучені НЕ з перших декількох РВВШ, що містять основну інформацію про помилки. В роботі [40] запропоновано метод ранньої діагностики відмов ЕМО, який базується на мультимасштабній ентропії та АННСВ. Автори [41] об'єднали АННСВ з деревом рішень для досягнення ефективного діагностування несправностей асинхронних двигунів.

В наступних наукових джерелах інформації розглядається метод еволюційного алгоритму (ЕА), який надає зовсім новий спосіб вирішення складних задач оптимізації, що мають значні переваги простого принципу та зручного впровадження, особливо у випадку вирішення великомасштабних задач динамічної оптимізації. ЕА пред-

ставляє собою процес імітації біологічної еволюції та групового інтелекту. На рисунку 4 зображене EA, що використовується для діагностики несправностей.

Основна функція еволюційного алгоритму з виявлення несправностей – це оптимізування методів обробки сигналів. Тобто EA використовуються для оптимізації параметрів фільтрації або функцій вейвлет-бази, щоб покращити виявлення ознак несправностей ЕМО. В даний час широко використовується генетичний алгоритм (ГА) та оптимізація частинок (ОЧ) при виявленні несправностей. Автори роботи [42] запропонували адаптивний каскадний метод стихастичного резонансу для виявлення слабких імпульсних ознак, занурених в шум; параметри цього методу були синхронно оптимізовані ГА, а результати показали, що запропонований метод був придатним для виявлення слабких ударних характеристик коробки передач. Комбінація оптимального вейвлету Морле та автокореляційного аналізу використана для виявлення ранньої стадії деформації підшипників кочення, а для оптимізації параметрів фільтрації вейвлету Морле [48] було використано ГА.

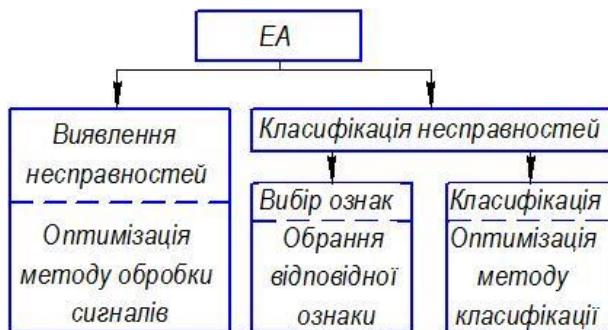


Рисунок 4 – Еволюційний алгоритм для діагностики несправностей електромеханічного обладнання (за джерелом [42])

EA можуть одночасно шукати декілька областей простору рішення та включати обчислювальний механізм паралельної обробки і характеристики самоорганізації та самонавчання без будь-якої іншої допоміжної інформації. EA наразі застосовуються до діагностики несправностей шляхом поєднання з іншими алгоритмами. Автори [43] запропонували оптимізувати структурні параметри ШНМ за допомогою ГА, а саме кількість прихованих шарів, функція активації прихованих і вихідних шарів, кількість нейронів у прихованому шарі та алгоритм навчання. Інші розробники [44] застосували ГА для оптимізації ШНМ при діагностіці несправностей підшипників кочення. Х. Шао та інші автори [45] використали ОЧ для визначення структури ДВП та використовували оптимізовану ДВП у діагностіці несправностей підшипників кочення. І навпаки, для виявлення несправностей використовується вибір функцій на основі EA, що поєднуються з методом класифікації. Тому процес вибору функції дійсно потрібен перед класифікацією несправностей. Значні дослідження були проведенні з цього питання. В роботі [46] використано ШНМ для класифікації стану змащення і використовували ГА для пошуку оптимального простору характеристик. Наступні розробники [47] використовували ГА для вибору оптимального набору функцій, який використовувався як вхід ШНМ для класифікації механічних дефектів. ГА може успішно визначити бажану кількість хороших функцій у великому просторі пошуку. Перевага методу ГА-ШНМ виявляється в точності навчання та успішності класифікації. М. Ахмед та інші автори наукової роботи [48] інтегрували ГА та ШНМ для вибору ефективних характеристик несправностей у поршневих компресорах. В роботі [49] авторами було обрано оптимальні характеристики різних етапів на основі ГА, а потім об'єднані з ШНМ для діагностики несправностей коробки передач для вибору оптимальних характеристичних параметрів у часі, частотах та частотно-часових доменах.

Наступним ми розглянемо новий метод опорних векторів (МОВ), який заснований на статистичній теорії і не належить ШНМ [17]. Даний метод вирішує задачі оптимальної класифікації, використовуючи принцип мінімізації структурного ризику, та має невеликий попит на зразки, тому добре підходить для встановлення моделі діагностики несправностей. МОВ, який вперше був введений в поле діагностики відмов Л.Б. Джеком і А.К. Нанді [50], використовувався для отримання класифікації несправностей підшипників. Даний метод широко використовувався в механічній діагностіці несправностей в останні роки. П. Конар та інші його співавтори в своїй роботі [51] використовували вейвлет перетворення та МОВ для виявлення несправностей підшипника в асинхронних двигунах. Наступні автори [52] запропонували метод діагностики несправностей на основі надлишкового вейвлет-перетворення другого порядку для діагностування відмов, який був об'єднаний з набором нерівностей та МОВ. Дж. Ченг та інші [53] запропонували розсіювання сингулярного значення та МОВ на основі МЕР для діагностики несправностей підшипників кочення та передач. У цьому методі функція векторної матриці була сингулярним значенням чутливої складової вбудованих функцій (ВФ), розкладеної МЕР, що розглядалася як вхід МОВ для інтелектуальної діагностики. Наступний автор [54] запропонував гіbridну модель на основі ентропії перестановок, ЕМЕР та МОВ для діагностики несправностей двигуна. Вібраційний сигнал спочатку розкладався на сукупність компонентів ВФ за допомогою ЕМЕР. Потім був отриманий вектор переносу ентропії перших декількох ВФ, який розглядався як вхід оптимізованого МОВ для досягнення класифікації типу помилок. Деякі покращені МОВ, такі як ансамбль МОВ (АМОВ) та нечіткий МОВ (НМОВ), були запропоновані для вирішення

проблем класифікації неоднорідних помилок. Даний класифікатор не тільки вирішує проблему багаторівневої класифікації, але також значно покращує її показники в порівнянні з єдиним МОВ [55]. В роботі [56] запропоновано комбіноване багатоступеневе НЕ та АМОВ для діагностики несправностей підшипників. НМОВ також використовувався для вирішення багатьох задач класифікації [57]. Дж. Ханг і інші співавтори [58] використовували ЕМЕР для витягання векторів несправностей, а НМОВ було прийнято для вирішення багатоканальних проблем при діагностиці несправностей вентилятора. Порівняння результатів класифікації НМОВ із зворотним поширенням та стандартним МОВ показало, що НМОВ мав високу точність класифікації.

Незважаючи на те, що МОВ досяг певних успіхів у дослідженні діагностики несправностей електромеханічного обладнання, деякі питання потребують подальшого вивчення, а саме вибір відповідної функції ядра та її параметрів; вибір відповідного мульти-класифікаційного алгоритму для задоволення потреб багатофункціонального класифікатора; покращення швидкості навчання; а також поєднання інших методів діагностики несправностей на основі знань, таких як нечітка логіка та нейронна мережа з МОВ для діагностики несправностей.

Висновки. 1. Штучні нейронні мережі є одним із найбільш часто використовуваних класифікаторів методів інтелектуальної діагностики несправностей, що мають можливості високого рівня навчання та узагальнюючих характеристик. Точність штучних нейронних мереж сильно залежить від навчальної вибірки. У випадку обмеженої кількості об'ємів вибірки ШНМ часто демонструють слабкі можливості узагальнення, тому, звичайно, ШНМ застосовуються у разі достатнього розміру тренувального зразка.

2. Метод опорних векторів (МОВ) вводиться в діагностику відмов та прогнозування несправностей машини для невеликого розміру вибірки з урахуванням його високої точності та хорошого узагальнення. Але його спеціально необхідно комбінувати для багато класової класифікації, навчання також займає багато часу у роботі з масштабними даними. Для подолання вищезгаданих проблем, було запропоновано декілька покращених методів на основі МОВ, продуктивність яких краща, ніж у єдиного МОВ.

3. ШНМ і МОВ багато в чому залежать від вибору функцій на основі попередніх знань технологій обробки сигналів. Вибрані функції можуть бути придатними тільки для незначних проблем.

4. ГНМ може адаптивно обирати необхідну інформацію з вихідних даних без необхідності попереднього знання через глибинну структуру, тому його можна використовувати для інтелектуальної діагностики відмов, але тільки у тому випадку, коли важко визначити несправності, проте, ГНМ потребує більше часу в навчанні в порівнянні з ШНМ.

5. База нечітких правил є ключовим моментом і вузьким місцем у розробці нечіткої логіки, яка базується на експертних знаннях та досвіді. За відсутності самонавчання та самореалізації, НЛ часто поєднується з іншими алгоритмами, такими як нейронна мережа, дерево збоїв та експертна система, для досягнення виявлення помилок та прогнозів.

6. Еволюційні алгоритми є найпоширенішими у діагностиці відмов. ЕА були застосовані до виявлення несправностей, разом з іншими методами обробки сигналів, такими як вейвлет-перетворення, МЕР, стохастичний резонанс та інші.

7. На підставі аналізу останніх досліджень визначено, що останнім часом в застосуванні штучного інтелекту досягнуто значний прогрес, але дослідники зосередили увагу на підвищенні ефективності алгоритму оптимізації та зменшенні кількості ітерацій.

8. Дані методи обчислювальної інтелектуальної діагностики потребують подальшого вивчення та удосконалення для використання в інженерній практиці, тому злиття різних методів може сформувати новий гіbridний алгоритм, який буде об'єднувати переваги різних методів.

СПИСОК ЛІТЕРАТУРИ

1. Вавилов В.П. Александров А.Н. Инфракрасная термографическая диагностика в строительстве и энергетике. М.: НТФ «Энергопрогресс», 2003. С. 360.
2. A. K. S. Jardine, D. M. Lin, D. Banjevic. A review on machinery diagnostics and prognostics implementing condition-based maintenance. *Mechanical Systems and Signal Processing*, 2006, 20(7): 1483–1510.
3. Z. W. Gao, C. Cecati, S. X. Ding. A Survey of Fault Diagnosis and Fault-Tolerant Techniques Part I: Fault Diagnosis with Model-Based and Signal-Based Approaches. *IEEE Transactions on Industrial Electronics*, 2015, 62(6): 3757–3767.
4. А. И. Хальясмаа, С. А. Дмитриев, С. Е. Кокин, Д. А. Глушков. Диагностика электрооборудования электрических станций и подстанций: учебное пособие/ А. И. Хальясмаа [и др.]. – Екатеринбург: Изд-во Урал. ун-та, 2015. – 64 с. ISBN 978-5-7996-1493-5.
5. R. B. Randall. Vibration-based condition monitoring: industrial, aerospace and automotive applications. Chichester: John Wiley & Sons, Ltd., 2011.
6. J. Z. Sikorska, M. Hodkiewicz, L. Ma. Prognostic modelling options for remaining useful life estimation by industry. *Mechanical Systems and Signal Processing*, 2011, 25(5): 1803–1836.
7. I. El-Thalji, E Jantunen. A summary of fault modelling and predictive health monitoring of rolling element bearings. *Mechanical Systems and Signal Processing*, 2015, 60–61: 252–272.

8. M. Eremia, C. C. Liu, A. Edris. Advanced Solutions in Power Systems: HVDC, FACTS, and Artificial Intelligence. Hoboken: John Wiley & Sons, Inc., 2016.
9. V. Piuri, F. Scotti, M. Roveri. Computational Intelligence in Industrial Quality Control// Proceedings of the IEEE 2005 International Workshop on Intelligent Signal Processing, Faro, Portugal, September 1–3, 2005: 4–9.
10. X. Y. Wang, Y. M. Ding. Adaptive Real-time Predictive Compensation Control for 6-DOF Serial Arc Welding Manipulator. *Chinese Journal of Mechanical Engineering*, 2010, 23(3): 361–366.
11. Q. K. Al-Shayea. Artificial neural networks in medical diagnosis. *International Journal of Computer Science Issues*, 2011, 8(2): 150–154.
12. R. D. Labati, A. Genovese, E. Muñoz, et al. Computational intelligence for industrial and environmental applications// Proceedings of the IEEE 8th International Conference on Intelligent Systems, Sofia, Bulgaria, September 4–6, 2016: 8–14.
13. P. K. Kankar, S. C. Sharma, S. P. Harsha. Fault diagnosis of ball bearings using machine learning methods. *Expert Systems with Applications*, 2011, 38(3): 1876–1886.
14. S. Kar, S. Das, P. K. Ghosh. Applications of neuro fuzzy systems: A brief review and future outline. *Applied Soft Computing*, 2014, 15: 243–259.
15. J. Schmidhuber. Deep learning in neural networks: An overview. *Neural Networks*, 2015, 61: 85–117.
16. G. B. Huang, Q. Y. Zhu, C. Siew. Extreme learning machine: Theory and applications. *Neurocomputing*, 2006, 70(1): 489–501.
17. L. Cuadra, S. Salcedo-Sanz, J. C. Nieto-Borge, et al. Computational intelligence in wave energy: Comprehensive review and case study. *Renewable and Sustainable Energy Reviews*, 2016, 58: 1223–1246.
18. R. C. Cavalcante, R. C. Brasileiro, V. L. F. Souza, et al. Computational Intelligence and Financial Markets: A Survey and Future Directions. *Expert Systems with Applications*, 2016, 55: 194–211.
19. O. P. Mahela, A. G. Shaik, N. Gupta. A critical review of detection and classification of power quality events. *Renewable and Sustainable Energy Reviews*, 2015, 41: 495–505.
20. S. Khokhar, A. A. B. Mohd Zin, A. S. B. Mokhtar, et al. A comprehensive overview on signal processing and artificial intelligence techniques applications in classification of power quality disturbances. *Renewable and Sustainable Energy Reviews*, 2015, 51: 1650–1663.
21. P. Henriquez, J. B. Alonso, M. A. Ferrer, et al. Review of Automatic Fault Diagnosis Systems Using Audio and Vibration Signals. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 2014, 44(5): 642–652.
22. M. S. Kan, A. C. C. Tan, J. Mathew. A review on prognostic techniques for non-stationary and non-linear rotating systems. *Mechanical Systems and Signal Processing*, 2015, 62–63: 1–20.
23. J. D. Wu, C. H. Liu. An expert system for fault diagnosis in internal combustion engines using wavelet packet transform and neural network. *Expert Systems with Applications*, 2009, 36(3): 4278–4286.
24. Y. G. Lei, Z. J. He, Y. Y. Zi. EEMD method and WNN for fault diagnosis of locomotive roller bearings. *Expert Systems with Applications*, 2011, 38(6): 7334–7341.
25. G. F. Bin, J. J. Gao, X. J. Li, et al. Early fault diagnosis of rotating machinery based on wavelet packets—Empirical mode decom-position feature extraction and neural network. *Mechanical Systems and Signal Processing*, 2012, 27: 696–711.
26. L. L. Cui, C. Q. Ma, F. B. Zhang, et al. Quantitative diagnosis of fault severity trend of rolling element bearings. *Chinese Journal of Mechanical Engineering*, 2015, 28(6): 1254–1260.
27. N. Saravanan, K. I. Ramachandran. Incipient gear box fault diagnosis using discrete wavelet transform (DWT) for feature extraction and classification using artificial neural network (ANN). *Expert Systems with Applications*, 2010, 37(6): 4168–4181.
28. Z. Zhao, Q. S. Xu, M. P. Jia. Improved shuffled frog leaping algorithm-based BP neural network and its application in bearing early fault diagnosis. *Neural Computing and Applications*, 2016, 27(2): 375–385.
29. X. J. Guo, L. Chen, C. Q. Shen. Hierarchical adaptive deep convolution neural network and its application to bearing fault diagnosis. *Measurement*, 2016, 93: 490–502.
30. G. E. Hinton, R. R. Salakhutdinov. Reducing the Dimensionality of Data with Neural Networks. *Science*, 2006, 313(5786): 504–507.
31. V. T. Tran, F. AlThobiani, A. Ball. An approach to fault diagnosis of reciprocating compressor valves using Teager–Kaiser energy operator and deep belief networks. *Expert Systems with Applications*, 2014, 41(9): 4113–4122.
32. F. Jia, Y. G. Lei, J. Lin, et al. Deep neural networks: A promising tool for fault characteristic mining and intelligent diagnosis of rotating machinery with massive data. *Mechanical Systems and Signal Processing*, 2016, 72–73: 303–315.
33. Z. X. Yang, X. B. Wang, J. H. Zhong. Representational Learning for Fault Diagnosis of Wind Turbine Equipment: A Multi-Layered Extreme Learning Machines Approach. *Energies*, 2016, 9(6): 379.
34. Y. Wei, X. Minqiang, L. Yongbo, et al. 1983. Gearbox fault diagnosis based on local mean decomposition, permutation entropy and extreme learning machine. *Journal of Vibroengineering*, 2016, 18(3): 1459–1473.
35. P. K. Wong, Z. Yang, C. M. Vong, et al. Real-time fault diagnosis for EA turbine generator systems using extreme learning machine. *Neurocomputing*, 2014, 128: 249–257.
36. H. Eristi. Fault diagnosis system for series compensated trans-mission line based on wavelet transform and

- adaptive neuro-fuzzy inference system. *Measurement*, 2013, 46(1): 393–401.
37. J. Chen, C. Roberts, P. Weston. Fault detection and diagnosis for railway track circuits using neuro-fuzzy systems. *Control Engineering Practice*, 2008, 16(5): 585–596.
38. S. M. El-Shal, A. S. Morris. A fuzzy expert system for fault detection in statistical process control of industrial processes. *IEEE Transactions on Systems, Man and Cybernetics-Part C: Applications and Reviews*, 2000, 30(2): 281–289.
39. J. Zheng, J. Cheng, Y. Yang. A rolling bearing fault diagnosis approach based on LCD and fuzzy entropy. *Mechanism and Machine Theory*, 2013, 70: 441–453.
40. L. Zhang, G. Xiong, H. Liu, et al. Bearing fault diagnosis using multi-scale entropy and adaptive neuro-fuzzy inference. *Expert Systems with Applications*, 2010, 37(8): 6077–6085.
41. V. T. Tran, B. Yang, M. Oh, et al. Fault diagnosis of induction motor based on decision trees and adaptive neuro-fuzzy inference. *Expert Systems with Applications*, 2009, 36(2): 1840–1849.
42. J. Wu, C. Hsu, G. Wu. Fault gear identification and classification using discrete wavelet transform and adaptive neuro-fuzzy inference. *Expert Systems with Applications*, 2009, 36(3): 6244–6255.
43. N. Lu, Z. H. Xiao, O. P. Malik. Feature extraction using adaptive multiwavelets and synthetic detection index for rotor fault diagnosis of rotating machinery. *Mechanical Systems and Signal Processing*, 2015, 52–53: 393–415.
44. M. Unal, M. Onat, M. Demetgul, et al. Fault diagnosis of rolling bearings using a genetic algorithm optimized neural network. *Measurement*, 2014, 58: 187–196.
45. H. Shao, H. Jiang, X. Zhang, et al. Rolling bearing fault diagnosis using an optimization deep belief network. *Measurement Science and Technology*, 2015, 26: 115002.
46. H. Sadegh, A. N. Mehdi, A. Mehdi. Classification of acoustic emission signals generated from journal bearing at different lubrication conditions based on wavelet analysis in combination with artificial neural network and genetic algorithm. *Tribology International*, 2016, 95: 426–434.
47. A. Saxena, A. Saad. Evolving an artificial neural network classifier for condition monitoring of rotating mechanical systems. *Applied Soft Computing*, 2007, 7(1): 441–454.
48. M. Ahmed, F. Gu, A. Ball. Feature Selection and Fault Classification of Reciprocating Compressors using a Genetic Algorithm and a Probabilistic Neural Network//2011 9th International Conference on Damage Assessment of Structures (DAMAS), London, United Kingdom, July 11–13, 2011: 12112.
49. M. Cerrada, R. Sánchez, D. Cabrera, et al. Multi-Stage Feature Selection by Using Genetic Algorithms for Fault Diagnosis in Gearboxes Based on Vibration Signal. *Sensors*, 2015, 15(9): 23903–23926.
50. L. B. Jack, A. K. Nandi. Support vector machines for detection and characterization of rolling element bearing faults. *Proceedings of the Institution of Mechanical Engineers Part C-Journal of Mechanical Engineering Science*, 2001, 215(9): 1065–1071.
51. P. Konar, P. Chattopadhyay. Bearing fault detection of induction motor using wavelet and Support Vector Machines (SVMs). *Applied Soft Computing*, 2011, 11(6): 4203–4211.
52. N. Li, R. Zhou, Q. Hu, et al. Mechanical fault diagnosis based on redundant second generation wavelet packet transform, neighborhood rough set and support vector machine. *Mechanical Systems and Signal Processing*, 2012, 28: 608–621.
53. J. Cheng, D. Yu, J. Tang. Application of SVM and SVD technique based on EMD to the fault diagnosis of the rotating machinery. *Shock and Vibration*, 2009, 16(1): 89–98.
54. X. Zhang, Y. Liang, J. Zhou, et al. A novel bearing fault diagnosis model integrated permutation entropy, ensemble empirical mode decomposition and optimized SVM. *Measurement*, 2015, 69: 164–179.
55. S. Wang, A. Mathew, Y. Chen, et al. Empirical analysis of support vector machine ensemble classifiers. *Expert Systems with Applications*, 2009, 36(3): 6466–6476.
56. J. Zheng, H. Pan, J. Cheng. Rolling bearing fault detection and diagnosis based on composite multiscale fuzzy entropy and ensemble support vector machines. *Mechanical Systems and Signal Processing*, 2017, 85: 746–759.
57. S. Abe. Fuzzy support vector machines for multilabel classification. *Pattern Recognition*, 2015, 48(6): 2110–2117.
58. J. Hang, J. Zhang, M. Cheng. Application of multi-class fuzzy support vector machine classifier for fault diagnosis of wind turbine. *Fuzzy Sets and Systems*, 2016, 297: 128–140.

REFERENCES

1. V. Vavilov, A. Aleksandrov (2003). Infrared thermographic diagnostics in construction and energy. M.: NTF «Energoprogress», p. 360.
2. A. K. S. Jardine, D. M. Lin, D. Banjevic (2006). A review on machinery diagnostics and prognostics implementing condition-based maintenance. *Mechanical Systems and Signal Processing*, 20(7), p.p.1483–1510.
3. Z. W. Gao, C. Cecati, S. X. Ding (2015). A Survey of Fault Diagnosis and Fault-Tolerant Techniques Part I: Fault Diagnosis with Model-Based and Signal-Based Approaches. *IEEE Transactions on Industrial Electronics*, 62(6), p.p. 3757–3767.
4. A. Halismaa, S. Dmitriev, S. Kokin, D. Glushkov (2015). Diagnostics of electrical equipment of power plants

- and substations: a manual / A. Halysmaa [and others]. - Ekaterinburg: Publishing house Ural. University. – p. 64. ISBN 978-5-7996-1493-5.
5. R. B. Randall (2011). Vibration-based condition monitoring: industrial, aerospace and automotive applications. Chichester: John Wiley & Sons.
 6. J. Z. Sikorska, M. Hodkiewicz, L. Ma (2011). Prognostic modelling options for remaining useful life estimation by industry. *Mechanical Systems and Signal Processing*, 25(5), p.p. 1803–1836.
 7. I. El-Thalji, E Jantunen (2015). A summary of fault modelling and predictive health monitoring of rolling element bearings. *Mechanical Systems and Signal Processing*, 60–61, p.p. 252–272.
 8. M. Eremia, C. C. Liu, A. Edris (2016). Advanced Solutions in Power Systems: HVDC, FACTS, and Artificial Intelligence. Hoboken: John Wiley & Sons, Inc.
 9. V. Piuri, F. Scotti, M. Roveri (2005). Computational Intelligence in Industrial Quality Control// Proceedings of the IEEE 2005 International Workshop on Intelligent Signal Processing, Faro, Portugal, September 1–3, p.p. 4–9.
 10. X. Y. Wang, Y. M. Ding (2010). Adaptive Real-time Predictive Compensation Control for 6-DOF Serial Arc Welding Manipulator. *Chinese Journal of Mechanical Engineering*, 23(3), p.p. 361–366.
 11. Q. K. Al-Shayea (2011). Artificial neural networks in medical diagnosis. *International Journal of Computer Science Issues*, 8(2), p.p. 150–154.
 12. R.D. Labati, A. Genovese, E. Muñoz, et al (2016). Computational intelligence for industrial and environmental applications// Proceedings of the IEEE 8th International Conference on Intelligent Systems, Sofia, Bulgaria, September 4–6, p.p. 8–14.
 13. P. K. Kankar, S. C. Sharma, S. P. Harsha (2011). Fault diagnosis of ball bearings using machine learning methods. *Expert Systems with Applications*, 38(3), p.p. 1876–1886.
 14. S. Kar, S. Das, P. K. Ghosh (2014). Applications of neuro fuzzy systems: A brief review and future outline. *Applied Soft Computing*, 15, p.p. 243–259.
 15. J. Schmidhuber (2015). Deep learning in neural networks: An overview. *Neural Networks*, 61, p.p. 85–117.
 16. G. B. Huang, Q. Y. Zhu, C. Siew (2006). Extreme learning machine: Theory and applications. *Neurocomputing*, 70(1), p.p. 489–501.
 17. L. Cuadra, S. Salcedo-Sanz, J. C. Nieto-Borge, et al (2016). Computational intelligence in wave energy: Comprehensive review and case study. *Renewable and Sustainable Energy Reviews*, 58, p.p. 1223–1246.
 18. R. C. Cavalcante, R. C. Brasileiro, V. L. F. Souza, et al (2016). Computational Intelligence and Financial Markets: A Survey and Future Directions. *Expert Systems with Applications*, 55, p.p. 194–211.
 19. O. P. Mahela, A. G. Shaik, N. Gupta (2015). A critical review of detection and classification of power quality events. *Renewable and Sustainable Energy Reviews*, 41, p.p. 495–505.
 20. S. Khokhar, A. A. B. Mohd Zin, A. S. B. Mokhtar, et al (2015). A comprehensive overview on signal processing and artificial intelligence techniques applications in classification of power quality disturbances. *Renewable and Sustainable Energy Reviews*, 51 p.p. 1650–1663.
 21. P. Henriquez, J. B. Alonso, M. A. Ferrer, et al (2014). Review of Automatic Fault Diagnosis Systems Using Audio and Vibration Signals. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 44(5), p.p. 642–652.
 22. M. S. Kan, A. C. C. Tan, J. Mathew (2015). A review on prognostic techniques for non-stationary and non-linear rotating systems. *Mechanical Systems and Signal Processing*, 62–63, p.p. 1–20.
 23. J. D. Wu, C. H. Liu. (2009) An expert system for fault diagnosis in internal combustion engines using wavelet packet transform and neural network. *Expert Systems with Applications*, 36(3), p.p. 4278–4286.
 24. Y. G. Lei, Z. J. He, Y. Y. Zi (2011). EEMD method and WNN for fault diagnosis of locomotive roller bearings. *Expert Systems with Applications*, 2011, 38(6): 7334–7341.
 25. G. F. Bin, J. J. Gao, X. J. Li, et al (2012). Early fault diagnosis of rotating machinery based on wavelet packets—Empirical mode decom- position feature extraction and neural network. *Mechanical Systems and Signal Processing*, 27, p.p. 696–711.
 26. L. L. Cui, C. Q. Ma, F. B. Zhang, et al (2015). Quantitative diagnosis of fault severity trend of rolling element bearings. *Chinese Journal of Mechanical Engineering*, 28(6), p.p. 1254–1260.
 27. N. Saravanan, K. I. Ramachandran (2010). Incipient gear box fault diagnosis using discrete wavelet transform (DWT) for feature extraction and classification using artificial neural network (ANN). *Expert Systems with Applications*, 37(6), p.p. 4168–4181.
 28. Z. Zhao, Q. S. Xu, M. P. Jia (2016). Improved shuffled frog leaping algorithm-based BP neural network and its application in bearing early fault diagnosis. *Neural Computing and Applications*, 27(2), p.p. 375–385.
 29. X. J. Guo, L. Chen, C. Q. Shen (2016). Hierarchical adaptive deep convolution neural network and its application to bearing fault diagnosis. *Measurement*, 93, p.p. 490–502.
 30. G. E. Hinton, R. R. Salakhutdinov (2006). Reducing the Dimensionality of Data with Neural Networks. *Science*, 313(5786), p.p. 504–507.
 31. V. T. Tran, F. AlThobiani, A. Ball (2014). An approach to fault diagnosis of reciprocating compressor valves using Teager–Kaiser energy operator and deep belief networks. *Expert Systems with Applications*, 41(9), p.p. 4113–4122.
 32. F. Jia, Y. G. Lei, J. Lin, et al (2016). Deep neural networks: A promising tool for fault characteristic mining and

- intelligent diagnosis of rotating machinery with massive data. *Mechanical Systems and Signal Processing*, 72–73, p.p. 303–315.
33. Z. X. Yang, X. B. Wang, J. H. Zhong (2016). Representational Learning for Fault Diagnosis of Wind Turbine Equipment: A Multi-Layered Extreme Learning Machines Approach. *Energies*, 9(6), p. 379.
 34. Y. Wei, X. Minqiang, L. Yongbo, et al.(2016). Gearbox fault diagnosis based on local mean decomposition, permutation entropy and extreme learning machine. *Journal of Vibroengineering*, 18(3), p.p. 1459–1473.
 35. P. K. Wong, Z. Yang, C. M. Vong, et al (2014). Real-time fault diagnosis for EAs turbine generator systems using extreme learning machine. *Neurocomputing*, 128, p.p. 249–257.
 36. H. Eristi (2013). Fault diagnosis system for series compensated trans-mission line based on wavelet transform and adaptive neuro-fuzzy inference system. *Measurement*, 46(1), p.p. 393–401.
 37. J. Chen, C. Roberts, P. Weston (2008). Fault detection and diagnosis for railway track circuits using neuro-fuzzy systems. *Control Engineering Practice*, 16(5), p.p. 585–596.
 38. S. M. El-Shal, A. S. Morris (2000). A fuzzy expert system for fault detection in statistical process control of industrial processes. *IEEE Transactions on Systems, Man and Cybernetics-Part C: Applications and Reviews*, 30(2), p.p. 281–289.
 39. J. Zheng, J. Cheng, Y. Yang (2013). A rolling bearing fault diagnosis approach based on LCD and fuzzy entropy. *Mechanism and Machine Theory*, 70, p.p. 441–453.
 40. L. Zhang, G. Xiong, H. Liu, et al (2010). Bearing fault diagnosis using multi-scale entropy and adaptive neuro-fuzzy inference. *Expert Systems with Applications*, 37(8), p.p. 6077–6085.
 41. V. T. Tran, B. Yang, M. Oh, et al (2009). Fault diagnosis of induction motor based on decision trees and adaptive neuro-fuzzy inference. *Expert Systems with Applications*, 36(2), p.p. 1840–1849.
 42. J. Wu, C. Hsu, G. Wu (2009). Fault gear identification and classification using discrete wavelet transform and adaptive neuro-fuzzy inference. *Expert Systems with Applications*, 36(3), p.p. 6244–6255.
 43. N. Lu, Z. H. Xiao, O. P. Malik (2015). Feature extraction using adaptive multiwavelets and synthetic detection index for rotor fault diagnosis of rotating machinery. *Mechanical Systems and Signal Processing*, 52–53, p.p. 393–415.
 44. M. Unal, M. Onat, M. Demetgul, et al (2014). Fault diagnosis of rolling bearings using a genetic algorithm optimized neural network. *Measurement*, 58, p.p. 187–196.
 45. H. Shao, H. Jiang, X. Zhang, et al (2015). Rolling bearing fault diagnosis using an optimization deep belief network. *Measurement Science and Technology*, 26, 115002.
 46. H. Sadegh, A. N. Mehdi, A. Mehdi (2016). Classification of acoustic emission signals generated from journal bearing at different lubrication conditions based on wavelet analysis in combination with artificial neural network and genetic algorithm. *Tribology International*, 95, p.p. 426–434.
 47. A. Saxena, A. Saad (2007). Evolving an artificial neural network classifier for condition monitoring of rotating mechanical systems. *Applied Soft Computing*, 7(1), p.p. 441–454.
 48. M. Ahmed, F. Gu, A. Ball (2011). Feature Selection and Fault Classification of Reciprocating Compressors using a Genetic Algorithm and a Probabilistic Neural Network//2011 9th International Conference on Damage Assessment of Structures (DAMAS), London, United Kingdom, July 11–13, 12112.
 49. M. Cerrada, R. Sánchez, D. Cabrera, et al (2015). Multi-Stage Feature Selection by Using Genetic Algorithms for Fault Diagnosis in Gearboxes Based on Vibration Signal. *Sensors*, 15(9), p.p. 23903–23926.
 50. L. B. Jack, A. K. Nandi (2001). Support vector machines for detection and characterization of rolling element bearing faults. *Proceedings of the Institution of Mechanical Engineers Part C-Journal of Mechanical Engineering Science*, 215(9), p.p. 1065–1071.
 51. P. Konar, P. Chattopadhyay (2011). Bearing fault detection of induction motor using wavelet and Support Vector Machines (SVMs). *Applied Soft Computing*, 11(6), p.p. 4203–4211.
 52. N. Li, R. Zhou, Q. Hu, et al (2012). Mechanical fault diagnosis based on redundant second generation wavelet packet transform, neighborhood rough set and support vector machine. *Mechanical Systems and Signal Processing*, 28, p.p. 608–621.
 53. J. Cheng, D. Yu, J. Tang (2009). Application of SVM and SVD technique based on EMD to the fault diagnosis of the rotating machinery. *Shock and Vibration*, 16(1), p.p. 89–98.
 54. X. Zhang, Y. Liang, J. Zhou, et al (2015). A novel bearing fault diagnosis model integrated permutation entropy, ensemble empirical mode decomposition and optimized SVM. *Measurement*, 69, p.p. 164–179.
 55. S. Wang, A. Mathew, Y. Chen, et al (2009). Empirical analysis of support vector machine ensemble classifiers. *Expert Systems with Applications*, 36(3), p.p. 6466–6476.
 56. J. Zheng, H. Pan, J. Cheng (2017). Rolling bearing fault detection and diagnosis based on composite multiscale fuzzy entropy and ensemble support vector machines. *Mechanical Systems and Signal Processing*, 85, p.p. 746–759.
 57. S. Abe (2015). Fuzzy support vector machines for multilabel classification. *Pattern Recognition*, 48(6), p.p. 2110–2117.
 58. J. Hang, J. Zhang, M. Cheng (2016). Application of multi-class fuzzy support vector machine classifier for fault diagnosis of wind turbine. *Fuzzy Sets and Systems*, 297, p.p. 128–140.

T. ALTUKHOVA

Industrial institute of SHEE «Donetsk National Technical University»

Methods of diagnostics of electromechanical equipment removal based on technologies of artificial intelligence.

Annotation. In this paper, the latest developments and applications of artificial intelligence for monitoring state and diagnostics of faults are considered, according to the categories of malfunctions' diagnostics. A comparative analysis of the characteristics of computational methods of diagnosis, which can be considered when choosing the appropriate method in a concrete situation for future research, is carried out. It has been determined that artificial neural networks are one of the most commonly used classifiers of methods of intelligent diagnostics of faults, which has the potential of high level of training and general characteristics. The accuracy of artificial neural networks (ANN) is highly dependent on the training sample. In the case of a limited number of sample volumes, ANNs often show weak generalization capabilities, therefore, of course, the ANN is used in the case of a sufficient size of the training sample. The method of support vectors machine (SVM) is introduced into the fault's diagnosis and prediction of machine failure for a small sample size, taking into account its high accuracy and good generalization. But SVM must be specially combined for a multi-class classification. Training of this method also takes a lot of time to work with large-scale data. The deep neural network (DNN) can adaptively choose the necessary information from the source without the need for prior knowledge through the deep structure, so it can be used for intelligent fault diagnosis, but only when it is difficult to identify faults, however, the DNN needs more time to study than ANN through depth structure. The basis of fuzzy rules is a key point and a bottleneck in the development of fuzzy logic (FL) based on expert knowledge and experience. In the absence of self-learning and self-realization, FL is often combined with other algorithms such as neural network, tree failure and expert system for to achieve error detection and predictions. Evolutionary algorithms are the most commonly used diagnostic failure. EAs have been applied to malfunctioning, along with other signal processing techniques, such as wavelet transforms, stochastic resonances, and others. Merging different methods can form a new hybrid algorithm which combines the benefits of different methods.

Key words: *electromechanical equipment, artificial neural networks, genetic algorithm, fuzzy logic, deep neural network, methods of diagnostics of malfunctions*