

Темчур В.С.Національний технічний університет України
«Київський політехнічний інститут імені Ігоря Сікорського»**Баган Т.Г.**Національний технічний університет України
«Київський політехнічний інститут імені Ігоря Сікорського»

МЕТОДИ ГЛИБОКОГО НАВЧАННЯ МОДЕЛЕЙ ДЛЯ ПРОГНОЗНОГО ОБСЛУГОВУВАННЯ

Враховуючи зростаючу кількість промислових об'єктів, а також кількість даних, яка отримується від різноманітного обладнання у всьому світі, рішення глибокого навчання стали популярними для прогнозного обслуговування, які відстежують активи для оптимізації завдань обслуговування. На сьогоднішній день саме прогнозне обслуговування стає найбільш пріоритетним методом обслуговування, оскільки він дозволяє суттєво підвищити загальну ефективність обладнання. Вибір найбільш підходящої архітектури для кожного випадку використання складний, враховуючи кількість прикладів, що застосовуються в подібних дослідженнях. Стаття спрямована на полегшення цього завдання шляхом огляду найсучасніших архітектур глибокого навчання, і те, як вони інтегруються з етапами прогнозованого технічного обслуговування для задоволення вимог промислових компаній. Це дає можливість виявити аномалії, аналізувати першопричини, оцінювати залишковий термін служби.

У статті викладено методологію для оцінки застосування моделей глибокого навчання в прогностичному обслуговуванні. Вона містить огляд і пояснення найбільш актуальних методів, керованих даними, зосереджуючись на найсучасніших архітектурах глибокого навчання, які застосовуються для прогнозного обслуговування. Це надає можливість огляду доступних методів у спрощеній та структурованій формі. Досліджується придатність моделей глибокого навчання для прогнозного обслуговування та порівнюються їхні переваги та недоліки зі статистичними та класичними моделями машинного навчання. Аналізуються поточні тенденції в публікаціях про прогнозне технічне обслуговування, визначаються недоліки, представляються проблеми дослідження та визначаються можливості та перспективи для подальшого дослідження.

Спершу виконано огляд контексту та різних застосувань прогнозного обслуговування. Після цього проведено ретельне дослідження різних типів моделей прогнозного обслуговування. Також виконано комплексний аналіз керованих даними моделей. Нарешті, реалізовано детальний огляд моделей глибокого навчання. Такий підхід дозволив отримати цілісне розуміння масштабів, перш ніж заглиблюватися у конкретні галузі досліджень.

Ключові слова: прогнозне технічне обслуговування, глибоке навчання, моделі керовані даними, штучні нейронні мережі, архітектура мережі.

Постановка проблеми. Технології штучного інтелекту та машинного навчання останніми роками привернули до себе значну увагу, завдяки їхній здатності створювати автоматизовані моделі для обробки великих обсягів даних, які зараз збираються і зростають в геометричній прогресії. Дослідницька тенденція машинного навчання переключилася на більш складні моделі, такі як ансамблеві методи та глибоке навчання, враховуючи їхню вищу точність при роботі з більшими наборами даних. Розвиток цих методів в основному пов'язаний з розвитком технологій, а саме зі збільшенням обчислювальних ресурсів та розвитком графічних процесорів. Ці методи дають

відмінні результати у багатьох галузях, таких як система виявлення вторгнень, комп'ютерне бачення чи обробка мови.

Технічне обслуговування можна трактувати як набір технічних, адміністративних та управлінських дій на протязі всього життєвого циклу об'єкта, спрямованих на підтримання або відновлення такого стану, в якому буде працездатним та виконуватиме необхідні функції. Також можна виділити три типи технічного обслуговування: «покращувальне» технічне обслуговування – направлене на підвищення надійності обладнання, ремонтпридатність і безпеку; «профілактичне» технічне обслуговування – зазвичай таке обслуго-

вування виконується періодично, за встановленим графіком; «коригувальне» технічне обслуговування – виконується вже після виходу обладнання з ладу і передбачає заміну пошкоджених частин частини. На сьогоднішній день найбільш розповсюдженим підходом є «профілактичне» технічне обслуговування.

У наш час відбувається перехід до четвертої промислової революції, так званої Industry 4.0. Ця революція зосереджена навколо конвергенції кіберфізичних систем і промислового Інтернету речей. Тут поєднується програмне забезпечення, обладнання фізичного рівня та інтелектуальні методи керування для вдосконалення промислових процесів. Такий підхід дозволяє удосконалити функції прогнозного технічного обслуговування, шляхом аналізу величезної кількості процесів і пов'язаних з ними даних за допомогою моніторингу стану (*Condition monitoring – CM*). Прогнозне технічне обслуговування (*Predictive maintenance – PdM*) визнано найбільш економічно ефективним підходом до техобслуговування через його потенціал для досягнення загальної ефективності обладнання (*Overall Equipment Effectiveness – OEE*) понад 90% шляхом передбачення потреб у техобслуговуванні і прогнозує значну віддачу від інвестицій, яка потенційно може досягати 1000%. Для передових компаній одним з головних завдань є удосконалення технічного обслуговування, оскільки саме цей крок може скоротити затрати до 60% [1]. Зокрема, *PdM* подовжує термін експлуатації компонентів, використовуючи їхній невикористаний потенціал, одночасно мінімізуючи час простою та витрати на заміну завдяки попереджувальній заміні компонентів до того, як виникнуть збої. Такий підхід запобігає дорогим поломкам і втратам часу виробництва через несподівані зупинки.

Аналіз останніх досліджень і публікацій. Дослідження прогнозного технічного обслуговування (*PdM*) можна розділити на три основні підходи: на основі фізичної моделі, на основі даних і гібридні методи. Підходи, засновані на фізичних моделях, використовують знання про системи для створення математичного представлення їх деградації [2, 3]. Хоча ці методи мають чітку фізичну інтерпретацію, їх може бути важко реалізувати в складних системах. Методи, керовані даними, з іншого боку, оцінюють системи шляхом моніторингу їх стану з використанням інформації, отриманої з історичних даних [4, 5]. Ці рішення охоплюють статистичні методи, функції надійності та методи штучного інтелекту. Вони добре підхо-

дять для складних систем, оскільки не вимагають повного розуміння того, як ці системи працюють. Однак пов'язати їх результат із фізичним контекстом може бути складніше. Гібридний підхід поєднує в собі елементи підходів, заснованих на фізичній моделі, і підходів, керованих даними [6]. В останні роки методи керовані даними та методи глибокого навчання набули популярності в промисловості завдяки збільшенню доступності машинних даних. Ця велика кількість даних дозволила розробити високоточні моделі *PdM* для складних систем.

У роботі [7] окреслено десять бажаних атрибутів для системи прогнозного технічного обслуговування: здатність швидко виявляти та діагностувати проблеми, диференціювати різні типи відмов, підтримувати надійність, ідентифікувати нові проблеми, оцінювати помилки класифікації, адаптуватися до мінливих умов, надавати пояснення, мати мінімальні вимоги до моделювання, ефективно обробляти обчислення та зберігання в реальному часі та виявляти велику кількість несправностей.

Дві основні проблеми в промислових сценаріях виникають через поведінку та мінливість даних. Навіть, якщо активи мають схожі характеристики, такі фактори, як механічні допуски, налаштування кріплення, зміни умов експлуатації та інші змінні можуть призвести до відмінностей. Ці фактори ускладнюють повторне використання моделей *PdM* на різних машинах і ресурсах. Додаткові виклики, які заслуговують на увагу, включають отримання високоякісних даних, правильну їх попередню обробку та виконання ефективного проєктування функцій для створення репрезентативного набору даних для проблеми. Крім того, кожне спостереження пов'язане з попередніми та має аналізуватися разом, що збільшує розмірність даних і ускладнює моделювання. Збір даних про несправності також є проблематичним, оскільки машини розроблені та керовані таким чином, щоб вони працювали правильно та запобігали збоєм, через це поломки виникають дуже рідко.

Зазвичай використовувані методи моніторингу стану обладнання включають різноманітні підходи, до них відносяться механічний ультразвук [12], аналіз вібрації [8], випробування частинок зносу [9], термографія, аналіз струму сигналу двигуна та неруйнівний контроль. Крім того, існують додаткові методи, такі як крутний момент, напруга та аналіз огинаючої, акустична емісія, вимірювання тиску і моніторинг температури. Статті [10, 11] розглядають ці методи, обговорюючи типи несправностей,

які вони можуть ідентифікувати, та їх практичне застосування. Вони підкреслюють потенціал включення даних про основні робочі умови для підвищення ефективності цих методів у комплексному аналізі прогностичного технічного обслуговування. Цей підхід передбачає збір даних із різних джерел, включаючи фізичні характеристики, продуктивність обладнання та робочі параметри.

Виклад основного матеріалу

Етапи прогнозованого обслуговування на основі даних. Багато з моделей глибокого навчання, використовуваних для прогностичного обслуговування (*PdM*), дотримуються тих же принципів, що й інші підходи до машинного навчання та статистики. Зокрема, більшість методів, що базуються на аналізі даних, проходять чіткі кроки, які описано в наступній послідовності: по-перше, виявлення аномалій, по-друге, проведення діагностики, по-третє, складання прогнозів і, нарешті, впровадження стратегій пом'якшення.

Як правило, ще дві дії виконуються передвищезгаданими в процесі підготовки даних для прогностичного обслуговування, який узгоджується із загальним аналітичним життєвим циклом даних [12]. Ці початкові етапи передбачають попередню обробку даних і розробку функцій та мають вирішальне значення для підвищення точності моделей прогностичного обслуговування шляхом формування репрезентативного набору даних. Важливо відзначити, що всі етапи прогностичного обслуговування повинні бути налаштовані, скориговані й реалізовані відповідно до вимог конкретних випадків використання та характеристик доступних даних. Крім того, розробка систем *PdM* є поступовим процесом, і методи, алгоритми та рішення, прийняті на кожному етапі, матимуть значний вплив на наступні етапи.

Розглянемо детальніше основні етапи створення системи *PdM*.

1. Попередня обробка

На цьому етапі відбувається підготовка зібраних даних для подальшої обробки. Важливо зазначити, що кожна модель має свої специфічні вимоги, які слід враховувати при виборі відповідного методу попередньої обробки для покращення продуктивності моделі. Нижче наведено огляд найпоширеніших методів: перевірка даних датчика забезпечує правильність зібраних даних; синхронізація використовується для збору сигналів, відібраних у різні часові мітки, з метою отримання керованих часових рядів/періодів даних; очищення даних видаляє або інтерполіє недоступні або відсутні

значення; повторна вибірка використовується для обробки незбалансованих даних, часто для підвищення точності дефіцитних класів даних про несправності або для обробки невеликих наборів даних, тоді як кодування або дискретизація проектує їх у новий простір у моделі, який легше обробляти, і змінює їхні типи характеристик; сегментація розділяє дані і дозволяє розпаралелювати їх для аналізу великих наборів даних; масштабування ознак, таке як нормалізація та стандартизація, масштабує всі ознаки до однакового або подібного простору і дозволяє порівнювати їх.

2. Розробка функцій

На цьому етапі виконується вилучення певної підмножини функцій, яка буде використовуватися як вхідні дані для моделей на подальших етапах. Ця процедура може позитивно вплинути на результати статистичних моделей і моделей машинного навчання. Хоча цей крок не є обов'язковим для моделей глибокого навчання, вони також можуть автоматично вивчати нові репрезентативні функції для вирішення завдань. Найпоширеніші підходи можна поділити на наступні категорії: виділення ознак в часовій та частотній областях, що враховують відношення ознак у часі та частоті [13]; проекція в новий простір, наприклад, за допомогою аналізу головних компонент [14], яка зменшує розмірність, зберігаючи важливу інформацію; методи конкатенації та об'єднання, які створюють нові функції шляхом поєднання існуючих; відбір ознак, що зменшує розмірність шляхом вилучення ознак з низькою дисперсією, зайвими або некорельованими, оскільки вони можуть ускладнювати модель, не додаючи додаткової інформації.

3. Виявлення аномалій

Основна мета полягає в визначенні, чи функціонує система в нормальних умовах. Ця задача може бути вирішена за допомогою трьох різних підходів, які базуються на моделях, побудованих на основі даних: класифікація, однокласова класифікація та кластеризація. Вони використовуються відповідно до наявності позначених даних різних класів під час навчання, наявності лише невідомих даних або наявності непозначених даних.

Для отримання уявлення про можливі типи відмов, базуючись на експертних знаннях, корисно використовувати аналіз режимів і наслідків відмов (*FMEA*) [15] і його покращений варіант, який включає аналіз критичності (*FMECA*). Це допомагає визначити пріоритети типів відмов або аномалій, які необхідно виявити, і розробити життєвий цикл аналізу даних.

Методи виявлення аномалій вимагають попередньої обробки даних, і деякі з них також можуть потребувати інженерних даних для ефективної роботи. Після попередньої обробки наступним кроком є вибір, навчання та оптимізація відповідної моделі для конкретного сценарію використання. Вибір методу виявлення аномалій та дані про сценарій використання визначатимуть подальші етапи прогнозування відмови обладнання.

4. Діагностика

Після виявлення аномалії, наступним кроком є проведення діагностики, щоб визначити, чи аномалія свідчить про несправний стан та чи існує ризик її подальшого розвитку. В іншому випадку може вказувати на недолік у моделі виявлення аномалій, і, можливо, її слід переглянути або перетренувати. Діагноз, зазвичай, ґрунтується на методах аналізу кореневої причини проблеми (*RCA*), які спрямовані на встановлення справжньої причини аномалії. Метод діагностики обирається в залежності від конкретної проблеми, яку необхідно вирішити. Існують різні підходи до цього етапу, і вони вибираються в залежності від методу виявлення аномалій та характеристик даних навчання. Наприклад, багатокласова класифікація, бінарна класифікація, класифікація одного класу та кластеризація можуть застосовуватися в залежності від того, чи містять дані різні типи відмов, або ж тільки спостереження відмовного класу, чи навіть не контролюються. Додатковим методом, який часто використовується разом з *RCA*, є вимірювання аномалій за допомогою індексу здоров'я (*HI*). Цей підхід спрямований на вимірювання збитків активів шляхом порівняння поточних робочих даних із історичними даними, які контролюються або не контролюються. *HI* може показувати відсоток відхилення від нормальних робочих даних або рівень погіршення на числовій шкалі, де вищий показник вказує на більше пошкодження або несправність, а найнижчий – відсутність пошкоджень. Етап діагностики спрощується, коли є більше інформації про дані та їхні мітки.

5. Прогнозування

Після виявлення та діагностики аномалії можна спостерігати за процесом деградації, використовуючи поточні умови роботи та стан машини на даний момент. Цей моніторинг концентрується на найважливіших чинниках для виявлення та діагностики аномалій, що сприяють виявленню потенційних поломок. Зазвичай цей етап виконується з використанням моделей залишкового терміну служби, які оцінюють залишковий час

або цикли до відмови, при наявності достатніх історичних даних для конкретного типу відмови. З іншого боку, якщо немає даних про погіршення, оцінку погіршення можна провести, спостерігаючи зміни індексу здоров'я (*HI*) або різниці між новими умовами роботи та добре встановленими нормальними умовами роботи. Обидві ці моделі також можуть надати певну впевненість у своїх прогнозах. Моделі прогнозу на основі даних можна розділити на чотири категорії в залежності від методів, на яких вони ґрунтуються. У наведеному нижче списку перераховані найбільш поширені методи, розділені на ці категорії для прогнозування деградації:

- на основі схожості (*Similarity-based*): порівнюється поточна продуктивність з минулою поведінкою до відмови, щоб зробити прогноз [17];

- статистичний: використовується історична статистика для оцінки деградації, така як моніторинг терміну служби у поєднанні з часом до відмови [4] або використання моделей виживання [19] для оцінки очікуваного терміну служби;

- аналіз часових рядів: використовуються методи, такі як *ARIMA* [17] на основі попередніх даних, фільтр Калмана для оцінки вектора стану, використовуючи неповні та зашумлені дані [20], а також методи Фур'є та генетичного програмування для створення поліноміальної функції шляхом оптимізації функції пристосованості;

- класифікація: діагностуються дані за відомим типом відмови або подібними даними про працездатність, а потім прогнозується деградація на основі історичних даних про цей клас. Поширені класифікатори, що використовуються в літературі, включають нейронні мережі прямого поширення (*NN*) [21], методи опорних векторів (*SVM*) [21], байєсівські мережі (*BN*) [22], приховані марківські моделі (*HMM*), методи на основі нечіткої логіки та випадкові ліси (*RF*) [23];

- регресія: прямо оцінюється індекс здоров'я (*HI*), аномалії або термін служби (*RUL*), що залишився, на основі вхідних даних. Сучасні алгоритми включають лінійні функції, нелінійні функції для обліку нелінійних взаємозв'язків, регресори на основі методів опорних векторів, адаптовані для регресії, регресію на основі релевантних векторів (*RVR*) на основі байєсівської регресії [17], згорткові нейронні мережі (*CNN*), процеси Вінера для моделювання деградації як безперервних стохастичних процесів та рекурентні нейронні мережі, такі як *LSTM* та *GRU* [5], які зберігають актуальну історичну інформацію для прогнозування при кожному спостереженні.

6. Пом'якшення

Після виявлення аномалії, визначення її основної причини та прогнозування терміну служби, що залишився, доступна достатня інформація для вживання заходів з технічного обслуговування, спрямованих на зменшення ймовірності збоїв на ранніх стадіях і, таким чином, запобігання виходу активів з ладу. Ця фаза передбачає планування та виконання необхідних заходів для відновлення належного робочого стану активів до того, як виникнуть будь-які поломки, тим самим зменшуючи витрати як на впровадження, так і на простой. Технічні спеціалісти з технічного обслуговування несуть відповідальність за виконання заходів із зменшення наслідків, які є невід'ємною частиною процесів управління технічним обслуговуванням і виробничими операціями. Моделі прогнозованого обслуговування на основі даних (*PdM*) повинні надавати підтримку, пропонуючи статистичну інформацію [16] та рекомендації експертам у галузі. Як наслідок, більш просунута форма пом'якшення досягається шляхом поєднання експертних знань у галузі та очікуваної деградації активів.

Огляд методів глибокого навчання. У наш час моделі глибокого навчання перевершують статистичні та традиційні моделі *ML* у багатьох сферах, включаючи *PdM*, коли існує достатньо історичних даних. Глибоке навчання – це частина широкого сімейства методів машинного навчання, яка ґрунтується на штучних нейронних мережах (*ANN*). Успіх глибокого навчання безпосередньо залежить від потужності техніки. На момент появи нейронних мереж потужності комп'ютерів були низькими, через що і самі мережі були досить слабкими. Саме тому в той час неможливо було створити велику кількість шарів нейронних мереж, а саме від кількості шарів залежать можливості мережі. Але з появою потужних станцій *GPU* (*Graphics Processing Unit*) і *TPU* (*Tensor Processing Unit*) все змінилося. Сучасний *Deep Learning* здатен упоратися з великими розмірами мереж.

У *ANN* нейрони обчислюють лінійну регресію вхідних даних з використанням вагових коефіцієнтів, а потім застосовують нелінійні функції активації, такі як сигмоїда, ректифікована лінійна одиниця (*ReLU*) або гіперболічний тангенс (*tanh*), для отримання вихідних значень. Параметри мережі зазвичай ініціалізуються випадковим чином, а потім налаштовуються шляхом порівняння вхідних даних з вихідними даними, використовуючи навчальний набір даних. Цей процес навчання здійснюється за допомогою алгоритму градієнтного спуску та алгоритму зворотного

поширення помилки, що дозволяють коригувати параметри кожного нейрона для зменшення помилки, яку мережа робить, використовуючи користувальницьку функцію вартості для обчислення помилки.

Розглянемо основні методи глибокого навчання в області прогнозного обслуговування.

- Нейронна мережа з архітектурою “*Feed-forward/MLP*” є однією з найбільш поширених та простих структур. Вона складається з нейронів, які організовані у шари, де всі нейрони в одному шарі пов'язані з усіма нейронами у наступному шарі, передаючи свій вихід як вхід іншим. Проте відсутні зв'язки між нейронами в одному шарі або між нейронами з різних попередніх шарів. Шари у цій архітектурі називаються: вхідний шар, приховані шари та вихідний шар. Нейронна мережа отримує набори спостережень, які поєднують вхідні та цільові функції, і навчається встановлювати зв'язки між ними шляхом мінімізації помилок, які вона генерує, порівнюючи вхідні дані з вихідними.

- Згорткова нейронна мережа (*CNN*) представляє собою тип прямої мережі, яка підтримує взаємозв'язок нейронів через застосування згорткових фільтрів. Ця архітектура знаходить широке застосування в задачах розпізнавання зображень, обробки сигналів, системах рекомендацій і обробці природної мови, серед інших сфер. Згортковий шар зазвичай має лінійну структуру та супроводжується застосуванням функції активації для отримання нелінійних відповідей. Після цього може використовуватися максимальний або середній шар об'єднання для зменшення розмірності. Крім того, більшість архітектур мають крок зведення, щоб отримати репрезентативні характеристики вхідних даних, які можна використовувати з іншими моделями машинного навчання або глибокого навчання для рішення різних завдань. Ваги в згорткових шарах розподіляються, що полегшує процес навчання.

- Рекурентна нейронна мережа (*RNN*) використовується для моделювання часових даних, зберігаючи стан, отриманий з попередніх вхідних даних мережі. Алгоритм зворотного розповсюдження в часі адаптує традиційний метод зворотного розповсюдження помилки для часових даних, що дозволяє впливати на попередні моменти в часі під час навчання. Проте цей підхід може призвести до проблеми зникнення або вибуху градієнту, яка робить нейронні мережі нездатними вивчати довгострокові залежності в даних. Для вирішення цієї проблеми були

розроблені спеціалізовані архітектури *RNN*, такі як довгокороткочасна пам'ять (*LSTM*) і стробований рекурентний блок (*GRU*), які використовують ворота для ефективного керування інформацією та забезпечення здатності моделі працювати з довгостроковими зв'язками в даних.

- Мережа глибоких переконань (*DBN*) і обмежена машина Больцмана (*RBM*) – це дві важливі архітектури в глибокому навчанні. *RBM* – це двовимірна, повністю зв'язана стохастична нейронна мережа з видимим та прихованим шаром, яка може вивчати розподіли ймовірностей в даних. Цю мережу можна навчати як з наглядом, так і без нагляду, і її головні застосування включають зменшення розмірності та класифікацію даних. З іншого боку, *DBN* – це стек *RBM*, де кожен два послідовні шари розглядаються як *RBM*. Спочатку *DBN* навчається без нагляду для зменшення розмірності даних, і після цього її можна перенавчити з використанням відповідних даних для виконання завдань класифікації.

- Автоенкодер (*AE*) [24] ґрунтується на ідеї розкладання сингулярних значень для виділення нелінійних характеристик, які найкраще репрезентують вхідні дані в меншому просторі. Він складається з двох компонентів: енкодера, який перетворює вхідні дані в прихований простір, і декодера, який перетворює дані з прихованого простору назад в простір, що відтворює вхідні дані з тим самим розміром. Мережа навчається мінімізувати помилку відтворення, яка представляє собою втрату між входом і виходом. Автоенкодери можуть бути розділені на недоповнені та надповні в залежності від розмірності їхнього латентного простору, який відповідає меншому або більшому (або рівному) розміру вхідних даних. Ці прості архітектури можуть бути розширені та модифіковані для вирішення різних завдань та проблем.

- До модифікацій автоенкодерів відноситься дешумний автоенкодер (*DAE*), який використовується для відновлення пошкоджених даних. Це тип надповного автоенкодера, де навчання контролюється для уникнення «функції ідентичності». Він навчається на парах даних з вхідними сигналами, які мають шум, і їх чистими виходами, з метою зменшення втрат між ними.

- Ще однією модифікацією є розріджений автоенкодер (*SAE*) [18], який обмежується в процесі навчання за допомогою штрафу за розрідженість, який базується на концепції дивергенції Кульбака-Лейблера. Ця архітектура ставить за мету зробити кожен нейрон розрідженим, щоб легше виділяти структурну інформацію з даних, у порівнянні

з звичайним автоенкодером і бути більш корисною для практичних застосувань.

- Генеративні моделі: варіаційний автокодер (*VAE*) і генеративна змагальна мережа (*GAN*). Обидві ці моделі розроблені для роботи без нагляду. *VAE* є генеративною моделлю і, отже, недетермінованою модифікацією звичайного автокодера, де латентний простір є безперервним. Зазвичай розподіл в латентному просторі є гаусовим, і декодер відтворює вихідні дані на основі випадкових вибірок та їхньої інтерполяції. *VAE* використовується для оцінювання розподілу даних, навчання представлення зразків даних і генерування синтетичних зразків серед іншого.

- *GAN* – це ще один тип генеративної нейронної мережі, яка складається з двох частин: генератора і дискримінатора. Генератор навчено створювати вихідні дані, які належать певному розподілу даних, використовуючи вектор представлення як вхідні дані. Дискримінатор навчений класифікувати свої вхідні дані незалежно від того, чи належать вони до певного розподілу даних. Вихід генератора підключається до входу дискримінатора, і вони навчаються разом, конкуруючи один з одним. Мета генератора полягає в тому, щоб перевершити дискримінатор, генеруючи вихідні дані з випадкових вхідних даних і намагаючись змусити дискримінатор класифікувати їх як належність до конкретного навченого розподілу. Роль дискримінатора полягає в тому, щоб відрізнити синтетичні, згенеровані дані від реальних, несинтетичних даних з навченого розподілу. Обидві частини навчаються разом, конкуруючи за перевагу одна над іншою, що відображається в теорії ігор. *GAN* може бути розширена на інші завдання машинного навчання, такі як контрольоване або навчання з підкріпленням.

- Самоорганізуюча карта (*SOM*) – це метод неконтрольованої організації внутрішнього представлення даних на основі штучних нейронних мереж. Вона використовує конкурентне навчання, у відмінну від типових штучних нейронних мереж, які використовують зворотне поширення та градієнтний спуск для створення нового простору, який зазвичай представляється у вигляді карти, зазвичай двовимірної. *SOM* базується на функціях сусідства для збереження топологічних властивостей вхідного простору в новому просторі, який представлений у вигляді клітинок. Серед інших застосувань, *SOM* може бути використана для кластеризації даних.

Висновки. Фізичні моделі та моделі, засновані на статичних даних для *PdM* широко використо-

увалися 15 років тому, але сьогодні вони менш поширені через складність або неможливість моделювання складних систем. Зараз, з приходом Industry 4.0, збільшенням обчислювальної потужності та автоматизації збору даних про машини та активи, все більшої популярності набуває глибоке навчання. Тим не менш, його двома основними недоліками є високі вимоги до навчальних даних і труднощі з поясненням моделі. Більше того, ці моделі повинні бути модифіковані та адаптовані для промислових характеристик і вимог до даних *PdM*. Таким чином, вибір типу моделі для програми *PdM* слід робити ретельно, проаналізувавши потреби кожного випадку використання. Можливо, його вимоги не задовольняються тенденцією дослідження машинного навчання, яка зараз є глибоким навчанням, і інші типи моделей є більш доцільними.

Незважаючи на те, що моделі глибокого навчання можуть досягти задовільних результатів, їх проектування, розробка та оптимізація мають досить багато складностей, найпоширенішими з яких є: вибір типу архітектури та структури, кількість прихованих шарів і нейронів, функції активації, умови регуляризації для запобігання переобладнанню та оптимізація параметрів навчання. З вищезазначених причин весь процес створення моделі *DL* не такий автоматичний, як може здатися на перший погляд. Крім того, щоб отримати конкурентоспроможні результати, необхідно здійснювати попередню обробку даних. Це може підвищити продуктивність моделі, але в той же час видалити релевантну інформацію. Крім того, ці кроки зазвичай можуть виконувати лише спеціалісти з обробки даних, що в свою чергу потребує додаткових витрат.

Більшість промислових компаній, які покладаються на стратегії коригувального та періодичного технічного обслуговування, можуть оптимізувати витрати шляхом інтеграції автоматичних моделей прогнозованого технічного обслуговування на основі даних. Ці моделі відстежують стан машин і компонентів, дослідження яких еволюціонували від статистичних до більш складних методів машинного навчання. Зараз їхні основні дослідження зосереджені на моделях глибокого навчання. Промислові компанії, які хочуть оптимізувати свої операції з технічного обслуговування, повинні перейти до прогнозного технічного обслуговування. Однак цю автоматизацію слід охоплювати від простіших до складніших моделей, завжди вибираючи ті, які краще відповідають їхнім конкретним потребам. У розробці та перевірці структури *PdM* повинні співпрацювати як експерти в галузі, так і дослідники даних. Ця гібридна модель може скористатися перевагами як підходів, заснованих на статичних даних, так і підходів, керованих даними, що призведе до отримання точної, але інтерпретаційної моделі.

Сучасні промислові компанії збирають багато даних шляхом моніторингу активів у нормальних робочих умовах і майже без даних про збої. Таким чином, дослідження неконтрольованих та однокласових алгоритмів класифікації є актуальними для галузі прогнозного обслуговування. Конкретно, такі архітектури, як автокодері, мережі глибокої *LSTM* або *CNN* є одними з найбільш досліджених типів архітектур, які дозволяють виконувати моделювання часових рядів даних. Тим не менш, розробка та оптимізація архітектур *DL* в основному керуються попереднім досвідом та методом проб і помилок.

Список літератури:

1. Balbir S Dhillon. 2002. Engineering maintenance: a modern approach. cRc press. 1–224 pages.
2. Ling Li, Min Liu, Weiming Shen, and Guoqing Cheng. 2017. An expert knowledge-based dynamic maintenance task assignment model using discrete stress-strength interference theory.
3. Y. Li, T. R. Kurfess, and S. Y. Liang. 2000. Stochastic prognostics for rolling element bearings. *Mechanical Systems and Signal Processing* 14, 5 (2000), 747–762.
4. Marcia Baptista, Shankar Sankararaman, Ivo P. de Medeiros, Cairo Nascimento, Helmut Prendinger, and Elsa M.P. Henriques. 2018. Forecasting fault events for predictive maintenance using data-driven techniques and ARMA modeling. *Computers and Industrial Engineering* 115 (2018), 41–53.
5. Mei Yuan, Yuting Wu, and Li Lin. 2016. Fault diagnosis and remaining useful life estimation of aero engine using LSTM neural network. In *AUS 2016 - 2016 IEEE/CSAA International Conference on Aircraft Utility Systems*. IEEE, 135–140.
6. Chong Zhang, Pin Lim, A. K. Qin, and Kay Chen Tan. 2017. Multiobjective Deep Belief Networks Ensemble for Remaining Useful Life Estimation in Prognostics. *IEEE Transactions on Neural Networks and Learning Systems* 28, 10 (2017), 2306–2318.
7. Venkat Venkatasubramanian, Raghunathan Rengaswamy, Kewen Yin, and Surya N. Kavuri. 2003. A review of process fault detection and diagnosis part I: Quantitative model-based methods. *Computers and Chemical Engineering* 27, 3 (2003), 293–311.

8. Gopi Krishna Durbhaka and Barani Selvaraj. 2016. Predictive maintenance for wind turbine diagnostics using vibration signal analysis based on collaborative recommendation approach. In 2016 International Conference on Advances in Computing, Communications and Informatics, ICACCI 2016. 1839–1842.
9. M. Woldman, T. Tinga, E. Van Der Heide, and M. A. Masen. 2015. Abrasive wear based predictive maintenance for systems operating in sandy conditions. *Wear* 338-339 (2015), 316–324.
10. Fausto Pedro García Márquez, Andrew Mark Tobias, Jesús María Pinar Pérez, and Mayorkinos Papaefthymiou. 2012. Condition monitoring of wind turbines: Techniques and methods. *Renewable Energy* 46 (2012), 169–178.
11. Sule Selcuk. 2017. Predictive maintenance, its implementation and latest trends. *Proceedings of the Institution of Mechanical Engineers, Part B: Journal of Engineering Manufacture* 231, 9 (2017), 1670–1679.
12. Samir Khan and Takehisa Yairi. 2018. A review on the application of deep learning in system health management. *Mechanical Systems and Signal Processing* 107 (2018), 241–265.
13. Weiting Zhang, Dong Yang, and Hongchao Wang. 2019. Data-Driven Methods for Predictive Maintenance of Industrial Equipment: A Survey. *IEEE Systems Journal* 13, 3 (2019), 2213–2227.
14. Mikel Canizo, Enrique Onieva, Angel Conde, Santiago Charramendieta, and Salvador Trujillo. 2017. Real-time predictive maintenance for wind turbines using Big Data frameworks. In 2017 IEEE International Conference on Prognostics and Health Management, ICPHM 2017. 70–77.
15. Claudio Passarella. 2018. Failure modes and effects analysis. *Control* 31, 10 (2018), 72–73.
16. Raji Murugan and Raju Ramasamy. 2015. Failure analysis of power transformer for effective maintenance planning in electric utilities. *Engineering Failure Analysis* 55 (2015), 182–192.
17. Partha Adhikari, Harsha Gururaja Rao, and Dipl.-Ing Matthias Buderath. 2018. Machine Learning based Data Driven Diagnostics & Prognostics Framework for Aircraft Predictive Maintenance. 10th International Symposium on NDT in Aerospace, October 24-26, 2018, Dresden, Germany MI (2018), 1–15.
18. Zhenyu Wu, Hao Luo, Yunong Yang, Xinning Zhu, and Xiaofeng Qiu. 2018. An unsupervised degradation estimation framework for diagnostics and prognostics in cyber-physical system. In *IEEE World Forum on Internet of Things, WF-IoT 2018 - Proceedings*, Vol. 2018-January. 784–789.
19. Zhongju Zhang and Pengzhu Zhang. 2015. Seeing around the corner: an analytic approach for predictive maintenance using sensor data. *Journal of Management Analytics* 2, 4 (2015), 333–350.
20. Wlamir Olivares Loesch Vianna and Takashi Yoneyama. 2018. Predictive Maintenance Optimization for Aircraft Redundant Systems Subjected to Multiple Wear Profiles. *IEEE Systems Journal* 12, 2 (2018), 1170–1181.
21. Mona Khatami Rad, Mohammadsan Torabizadeh, and Amin Noshadi. 2011. Artificial neural network-based fault diagnostics of an electric motor using vibration monitoring. In *Proceedings 2011 International Conference on Transportation, Mechanical, and Electrical Engineering, TMEE 2011*. IEEE, 1512–1516.
22. Dongjin Lee. 2019. Evaluating reliability of complex systems for Predictive maintenance.
23. Clemens Gutsch, Nikolaus Furian, Josef Suschnigg, Dietmar Neubacher, and Siegfried Voessner. 2019. Log-based predictive maintenance in discrete parts manufacturing. *Procedia CIRP* 79 (2019), 528–533.
24. Samira Pouyanfar, Saad Sadiq, Yilin Yan, Haiman Tian, Yudong Tao, Maria Presa Reyes, Mei Ling Shyu, Shu Ching Chen, and S. S. Iyengar. 2018. A survey on deep learning: Algorithms, techniques, and applications. *Comput. Surveys* 51, 5 (2018), 92.

Temchur V.S., Bahan T.H. PREDICTIVE MAINTENANCE TECHNIQUES USING DEEP LEARNING ALGORITHMS

Given the growing number of industrial facilities, as well as the amount of data being collected from various equipment around the world, deep learning solutions have become popular for predictive maintenance that track assets to optimize maintenance tasks. Today, predictive maintenance is becoming the most priority method of maintenance, as it allows you to significantly increase the overall efficiency of the equipment. Choosing the most appropriate architecture for each use case is difficult given the number of examples used in similar studies. The article aims to facilitate this task by reviewing state-of-the-art deep learning architectures and how they integrate with predictive maintenance phases to meet the requirements of industrial companies. This makes it possible to detect anomalies, analyze the root causes, and estimate the remaining service life.

The article describes the methodology for evaluating the use of deep learning models in predictive maintenance. It provides an overview and explanation of the most relevant data-driven techniques, with a focus on state-of-the-art deep learning architectures applied to predictive maintenance. This provides an overview of the available methods in a simplified and structured form. The suitability of deep learning models for predictive maintenance is investigated and their advantages and disadvantages are compared with statistical and classical machine learning models. Current trends in predictive maintenance publications are analyzed, gaps are identified, research challenges are presented, and opportunities and perspectives for future research are identified.

First, an overview of the context and different applications of predictive maintenance is performed. This is followed by a thorough study of different types of predictive maintenance models. A comprehensive analysis of data-driven models was also performed. Finally, a detailed overview of deep learning models is implemented. This approach allowed for a holistic understanding of the scope before delving into specific areas of research.

Key words: predictive maintenance, deep learning, data-driven models, artificial neural networks, network architecture.