

Н. Н. ШАПОВАЛОВА, І. О. ДОЦЕНКО, ст. викладачі, А. А. ТРАЧУК, канд. техн. наук, доц.,  
І. В. СКРИННІКОВ, студент  
Криворізький національний університет

## ЗАСТОСУВАННЯ ІНСТРУМЕНТІВ ШТУЧНОГО ІНТЕЛЕКТУ ДЛЯ АНАЛІЗУ ЧАСОВИХ РЯДІВ

**Мета** дослідження полягає в аналізі та порівнянні продуктивності методів штучного інтелекту для завдань прогнозування часових рядів.

**Методи дослідження.** У роботі використано наступні методи дослідження: аналіз джерел з досліджуваної теми, статистичні методи, методи машинного навчання, нейронні мережі, методи економетрики, оптимізаційні методи, методи аналізу взаємодії зовнішніх факторів, методи обробки текстової інформації, формалізація побудованих моделей, методи проектування програмного забезпечення для розробки програмної моделі, емпіричні методи обґрунтування оптимальних параметрів навчання моделі, методи об'єктно-орієнтованого проектування та програмування.

**Наукова новизна** полягає в тому, що дослідження може зробити вагомий внесок у розуміння та вдосконалення ефективності методів штучного інтелекту для аналізу часових рядів, розкрити потенціал їх застосування в різних галузях та завданнях; розробку нових алгоритмів аналізу часових рядів на основі штучного інтелекту, що можуть враховувати специфічні вимоги та особливості певних доменів або типів даних, нові підходи до використання та комбінування різних технік машинного навчання для покращення точності моделей та їх здатності адаптуватись до реальних умов.

**Практична значимість** виконаної роботи полягає в тому, що розробка та оптимізація методів штучного інтелекту може призвести до покращення точності прогнозування часових рядів. Це може мати суттєве значення для промисловості, фінансів, сфери обслуговування та інших галузей, де точні прогнози грають важливу роль у прийнятті рішень. Використання штучного інтелекту для аналізу часових рядів може допомогти в ефективному управлінні ресурсами, такими як енергія, виробництво, транспорт і т. д. Автоматизоване прогнозування і оптимізація можуть сприяти ефективнішому використанню ресурсів та зменшенню витрат.

**Результати.** Проаналізовано та обґрунтовано вибір ефективних інструментів штучного інтелекту для прогнозування різного роду часових рядів, експериментально доведено ефективність обраних архітектур нейронних мереж.

**Ключові слова:** Часові ряди, методи штучного інтелекту, нейронні мережі, прогнозування.

doi: 10.31721/2306-5451-2024-1-58-46-52

**Проблема та її зв'язок з науковими і практичними задачами.** Часовий ряд (ЧР) – це послідовність даних, зібраних, вимірених чи спостережених у визначені моменти часу або відповідні позначення для таких моментів часу. У кожному елементі ЧР інформація пов'язана з відповідним моментом часу [1]. ЧР використовуються для аналізу та прогнозування динаміки різних явищ, таких як економічні показники, погода, захворюваність, та інші явища, які еволюціонують у часі.

Проблема в області прогнозування ЧР стає все більш актуальною, особливо з урахуванням швидкого розвитку сучасних технологій та динамічних змін у бізнес-та наукових сферах. Невизначеність та непередбачуваність подій утруднюють забезпечення точних та ефективних стратегій управління, що в свою чергу відкриває можливості для використання методів штучного інтелекту в проектуванні моделей прогнозування [2]. Виникає потреба в розробці нових та вдосконалення існуючих методів прогнозування, таких як рекурентні нейронні мережі (RNN), зокрема Long Short-Term Memory (LSTM) мережі, проведення порівняльного аналізу їхньої продуктивності та розробки підходів до оптимізації цих методів [3].

Розвиток ефективних стратегій управління бізнес-процесами та підтримки прийняття рішень на підставі точних прогнозів можливий завдяки використанню інструментарію, який надає штучний інтелект. Зокрема його застосування актуальне у таких сферах людської діяльності, як то: фінанси (прогнозування цін на фінансових ринках за допомогою ЧР дозволяє трейдерам та інвесторам приймати обґрунтовані рішення щодо покупки та продажу фінансових інструментів); економіка та бізнес (моделі ЧР використовуються для прогнозування обсягів продажів, попиту на товари та послуги, а також для оптимізації логістичних ланцюгів та управління запасами); метеорологія (аналіз ЧР погодних показників допомагає у прогнозуванні погодних умов, що має важливе значення для забезпечення безпеки громадян та управління різними галузями, такими як сільське господарство чи авіація; медицина (використання ЧР у медичних

дослідженнях дозволяє прогнозувати розвиток захворювань, визначати ефективність лікування та планувати медичні процедури); транспорт (аналіз ЧР у транспортному секторі допомагає управляти трафіком, планувати маршрути, та прогнозувати потреби у громадському та вантажному транспорті); енергетика (використання ЧР у сфері енергетики дозволяє прогнозувати споживання електроенергії, управляти електромережами та оптимізувати роботу енергетичних об'єктів).

**Аналіз досліджень і публікацій.** За останні кілька років тема застосування методів штучного інтелекту до аналізу ЧР стала актуальною через стрімкий розвиток технологій машинного навчання та глибокого навчання. Використання нейронних мереж є важливим напрямком досліджень у сфері аналізу ЧР. Однією з найпоширеніших архітектур є рекурентні нейронні мережі (RNN), які здатні враховувати попередній контекст у вирішенні завдань прогнозування. З урахуванням проблем виникнення градієнтного вибуху та затухання в RNN, Long Short-Term Memory (LSTM) мережі та їхні варіації, такі як Gated Recurrent Units (GRU), стали популярними вибором для моделювання завдань прогнозування ЧР [4, 5]. Розширенням цього підходу є використання глибоких нейронних мереж (Deep Neural Networks, DNN). Глибокі архітектури дозволяють вдосконалювати рівень абстракції взаємозв'язків у даних та отримувати більш точні прогнози.

Автоматизоване виділення залежностей в ЧР представляє собою ще один напрямок досліджень, що розширює можливості аналізу та прогнозування. Однією з ключових проблем в цьому контексті є необхідність виявлення та моделювання складних та неочевидних залежностей між подіями у ЧР. Традиційні методи не завжди здатні ефективно враховувати ці взаємодії, що робить актуальним розвиток автоматизованих методів виявлення та аналізу таких залежностей. Одним із підходів є використання методів машинного навчання для автоматизованого виявлення залежностей. Такі методи включають в себе використання різноманітних алгоритмів, таких як дерева рішень, глибокі нейронні мережі, та гібридні моделі [6].

Застосування глибокого навчання є важливою парадигмою в аналізі ЧР, забезпечуючи високий рівень точності та ефективності. Глибокі нейронні мережі, такі як глибокі звичайні мережі (Deep Neural Networks, DNN), розширюють можливості моделювання складних залежностей та виявлення нелінійних взаємозв'язків у ЧР. Однією з ключових переваг глибокого навчання є його здатність автоматично «витягувати» абстрактні репрезентації з даних, що особливо корисно у випадках складних ЧР [7, 8]. Архітектури, такі як глибокі автокодерери та варіанти рекурентних глибоких мереж, дозволяють моделювати внутрішню структуру даних, що важливо для аналізу динаміки ЧР.

Інтеграція з домен-специфічними даними є важливим етапом у розвитку аналізу ЧР, оскільки вона дозволяє моделям враховувати контекст та особливості конкретного галузевого середовища. Одним із підходів до інтеграції даних є використання методів трансферного навчання. Це дозволяє моделі адаптуватися до нового домену, використовуючи знання, набуте у попередніх завданнях [9]. Такий підхід особливо корисний, коли є обмежена кількість маркованих даних у цільовому домені. У деяких випадках, інтеграція з домен-специфічними даними включає в себе врахування експертного досвіду, наприклад, у вигляді експертних правил або додаткових показників.

Розвиток алгоритмів виявлення аномалій в ЧР є важливим в контексті забезпечення надійності та безпеки систем в реальному часі. Аномалії можуть вказувати на проблеми, відхилення чи несподівані події, що важливо виявляти та вчасно реагувати на них. Сучасні підходи включають в себе широкий спектр методів, які намагаються ефективно визначити невідповідності в ЧР. Одним з підходів є використання статистичних методів для виявлення відхилень від звичайних трендів [10-12]. Наприклад, методи, засновані на зовнішньому розподілі даних, можуть ефективно виявляти аномалії на основі стандартних відхилень чи квантилів. Використання нейронних мереж, таких як автокодерери, дозволяє моделям самостійно вивчати «нормальні» шаблони та ефективно виявляти аномальні відхилення в ЧР. Важливим аспектом є адаптивність алгоритмів до змінних умов та навчання «на льоту». Деякі методи використовують онлайн-навчання та постійне оновлення моделей, що дозволяє адаптуватися до змін в даних та уникати фальшивих спрацювань алгоритмів.

**Постановка завдання.** Необхідно дослідити ефективність методів штучного інтелекту для прогнозування ЧР. Дослідження проводитиметься в декілька етапів: визначення та формулювання сфери застосування моделі; вибір відповідних даних для навчання та тестування моделі;

вибір та налаштування параметрів відповідної моделі; використання метрик для оцінки якості моделі; використання методів порівняння моделей. Предметом дослідження є моделі прогнозування ЧР; ARIMA, ARIMAX, LSTM, GRU, RNN, Prophet, VAR, VARMA, TBATS.

**Викладення матеріалу та результати.** Модель ARIMA (AutoRegressive Integrated Moving Average) визначається як потужний інструмент прогнозування ЧР, що об'єднує в собі авторегресійний (AR), інтегральний (I) та ковзної середньої (MA) підходи. Ця модель знайшла широке застосування в аналізі ЧР, враховуючи її здатність ефективно враховувати тренди та сезонність. ARIMA складається з трьох основних компонентів: AR, який враховує попередні значення ряду; I, що відповідає за інтеграцію та усунення тренду; MA, що враховує помилки моделі. Параметри цих компонентів, позначені як  $(p, d, q)$ , визначають порядки авторегресії, інтеграції та ковзної середньої відповідно. Ефективність моделі ARIMA залежить від правильного вибору параметрів. Підбір оптимальних значень  $(p, d, q)$  використовується за допомогою методів, таких як автоматичний вибір ARIMA, що ґрунтується на статистичних підходах. Однак застосування цієї моделі може бути обмеженим у випадку нелінійних та нестационарних даних, що може впливати на точність прогнозу [13].

ARIMAX (ARIMA з екзогенними змінними) є розширенням базової моделі ARIMA, що дозволяє враховувати вплив зовнішніх факторів на ЧР. Одна з ключових відмінностей ARIMAX від класичного ARIMA полягає у включенні екзогенних (зовнішніх) змінних, які вважаються важливими для аналізу ЧР. Ці змінні можуть представляти фактори, що впливають на ряд, такі як економічні показники, погодні умови або інші зовнішні впливи. Враховуючи ці змінні, ARIMAX дозволяє моделювати більш складні взаємозв'язки та отримувати точніші прогнози. Для визначення параметрів ARIMAX та ваг екзогенних змінних використовується аналіз даних та методи оптимізації. Точність та ефективність ARIMAX може бути покращена за допомогою методів автоматичного підбору параметрів, таких як крос-валідація чи алгоритми оптимізації, для забезпечення оптимальної конфігурації моделі [14].

Модель Prophet розроблена фахівцями компанії Facebook і визначається своєю здатністю ефективно враховувати різноманітні компоненти ЧР, такі як сезонність, тренди та святкові ефекти. Тренд представляє собою загальний напрямок росту або спаду, сезонність ураховує регулярні патерни в даних, а святкові ефекти враховують вплив святкових періодів на ЧР. Модель доволі гнучка та проста в налаштуванні: користувачам надається можливість вручну додавати важливі події, враховувати зміни в сезонності та ефективно працювати з ЧР різних масштабів та грануляцій. Один із сильних аспектів Prophet – автоматизований підбір параметрів. Модель може самостійно визначити оптимальні значення параметрів, таких як ширина сезонності, збільшуючи точність прогнозу та зменшуючи зусилля користувача.

Long Short-Term Memory (LSTM) є особливим типом рекурентних нейронних мереж (RNN), розробленим для вирішення проблеми зникаючого градієнта та покращення здатності моделі розуміти та враховувати довгострокові залежності в ЧР та послідовностей. Основна перевага LSTM полягає в її здатності довго зберігати та враховувати інформацію з минулих кроків ЧР, що дозволяє ефективно робити прогнози для послідовностей зі складними взаємозв'язками. LSTM складається зі спеціальних блоків, таких як входи, виходи та ворота забування, які регулюють потік інформації через мережу. Це дозволяє контролювати, яка інформація передається та яка залишається у пам'яті на тривалий період. LSTM широко використовується в областях, де важлива довгострокова залежність в ЧР, таких як прогнозування погоди, фінансовий аналіз, обробка природної мови та багато інших. Здатність цієї моделі працювати з даними в реальному часі робить її популярною в задачах, де важлива точність та надійність прогнозів.

Gated Recurrent Unit (GRU) є типом рекурентних нейронних мереж (RNN), розробленим для вирішення проблем зникаючого градієнта та покращення ефективності в роботі з послідовними даними [15]. Цей тип нейронних мереж є вдосконаленою версією традиційних RNN, яка враховує короткострокову та довгострокову залежності в послідовностях. Головна ідея GRU полягає в узгодженому управлінні інформацією, яка передається внутрішнім станом мережі. Вона має два важливі гейти – Reset Gate та Update Gate. Reset Gate визначає, яка інформація буде забута, а Update Gate визначає, яка нова інформація буде додана. Це дозволяє GRU краще враховувати контекст інформації в часових послідовностях. Цей тип мереж складається з одиниць пам'яті, які взаємодіють між собою через Reset та Update гейти. GRU добре впроваджується з

завданнями, де важлива контекстуальна інформація в ЧР, таких як машинний переклад, розпізнавання мови, генерація тексту та аналіз часових послідовностей у фінансах.

Векторна авторегресійна модель (VAR) є статистичною моделлю, що використовується для аналізу та прогнозування взаємозв'язків між кількома ЧР. Ця модель дозволяє враховувати взаємодії та впливи між різними змінними в часі. VAR базується на ідеї авторегресії, де кожна змінна в часі розглядається як лінійна комбінація її попередніх значень та значень інших змінних. Модель може включати в вектор інші ЧР, що дозволяє досліджувати динаміку взаємовідносин між ними. VAR визначається порядком моделі, який вказує, скільки попередніх значень кожної змінної включено в модель.

Однією з основних переваг VAR є його здатність до прогнозування взаємодій між змінними та врахування множини змінних у системі. Вона часто використовується для аналізу макроекономічних змін, торговельного балансу, та інших областей, де важливо враховувати взаємодії між різними ЧР. VAR широко використовується в економічних дослідженнях, фінансовому аналізі, та інших областях, де важливо враховувати вплив різних факторів один на одне в часі. Вона також може бути використаний для ефективного прогнозування та розуміння поведінки системи.

Векторна авторегресійна та ковзна середня модель (VARMA) є розширенням векторної авторегресійної моделі (VAR), де додатково враховуються ковзні середні компоненти. Це статистичне інструментарій призначений для аналізу та прогнозування взаємозв'язків між багатьма ЧР. VARMA включає в себе як авторегресійні (AR) компоненти, що взято з моделі VAR, так і ковзні середні (MA) компоненти. Ця комбінація дозволяє більш точно моделювати та передбачати складні взаємозв'язки в багатовимірних ЧР. Модель VARMA( $p, q$ ) визначається порядками авторегресії ( $p$ ) та ковзних середніх ( $q$ ). Параметр  $p$  вказує кількість попередніх значень кожної змінної, які враховуються, тоді як  $q$  вказує кількість ковзних середніх, що враховуються.

VARMA дозволяє більш детально аналізувати та передбачати взаємодії між різними ЧР, оскільки враховуються не лише авторегресійні, а й ковзні середні впливи. Це особливо корисно при моделюванні систем, де змінні можуть взаємодіяти через час. VARMA широко використовується в економіці, фінансах, аналізі ЧР та інших областях. Її здатність моделювати та передбачати взаємозв'язки дозволяє ефективно аналізувати та прогнозувати поведінку системи.

TBATS (трапецієподібні адаптивні завдання) – це метод прогнозування ЧР, розроблений для ефективного управління різноманітністю та непередбачуваністю в динаміці даних. Він використовує адаптивні трапеції для моделювання та прогнозування складних змін в ЧР. Основною особливістю TBATS є його здатність автоматично адаптуватися до різних шаблонів та закономірностей в ЧР, таких як сезонність, тренди та календарні ефекти. Метод використовує комплексну апроксимацію сезонності та управління кількома характеристиками даних одночасно. Враховуються декомпозиція, адаптивність до трендів та сезонності, а також урахування календарних аномалій. Ця модель ефективна в умовах, коли ЧР мають складну структуру та різноманітні закономірності. Метод дозволяє точно передбачати ефекти сезонності, аномалії та тренди, роблячи його особливо корисним для прогнозування даних з великою кількістю непередбачуваних змін, тому широко використовується в прогнозуванні та аналізі ЧР у різних областях, таких як фінанси, економіка, логістика та інші.

Експеримент проведено на різних наборах історичних даних з відкритих джерел: дані про обмінний курс гривні (набір 1), дані про кількість населення (набір 2), дані про захворюваність на коронавірус (набір 3), дані про кількість дорожньо-транспортних пригод (набір 4). Ефективність моделей оцінювалась метрикою середньо-квадратичне відхилення (MSE). На графіках (рис. 1-4) продемонстровано якість прогнозованих показників на кожному наборі даних. На кожній діаграмі додатково виведено ЧР досліджуваних даних (блакитний) та прогнозоване значення (червоний).

На рис. 2 наведені лише моделі, які показали задовільний результат, моделі ж, помилка яких на порядок перевищує зазначені результати, не було відображено.

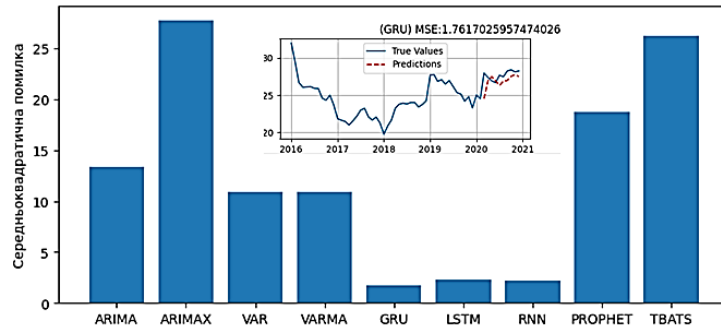


Рис. 1. Набір 1: порівняльна діаграма помилки моделей; графік прогнозної здатності найкращої моделі (GRU)

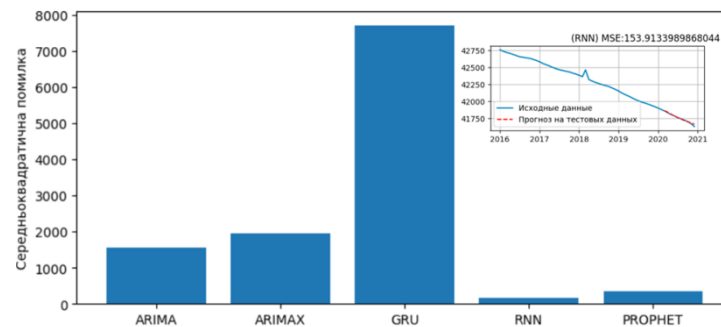


Рис. 2. Набір 2: порівняльна діаграма помилки моделей; графік прогнозної здатності найкращої моделі (RNN)

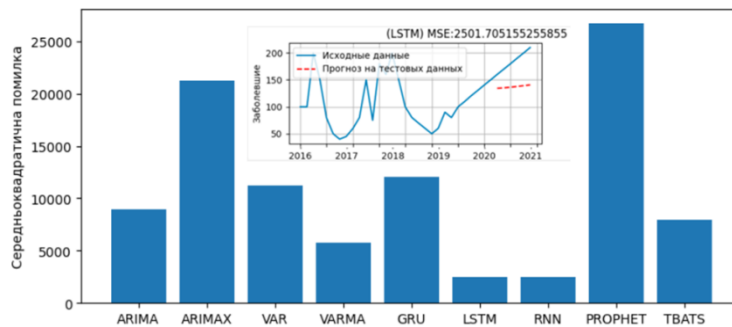


Рис. 3. Набір 3: порівняльна діаграма помилки моделей; графік прогнозної здатності найкращої моделі (LSTM)

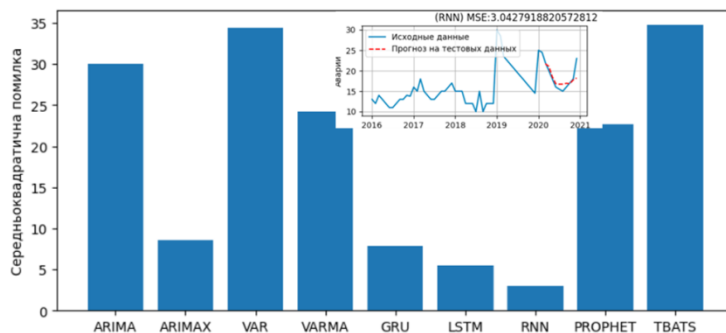


Рис. 4. Набір 4: порівняльна діаграма помилки моделей; графік прогнозної здатності найкращої моделі (RNN)

Як бачимо, найкращі результати були отримані в результаті застосування таких модифікацій нейронних мереж, як GRU, LSTM і RNN. Їх здатність збирати та зберігати інформацію протягом тривалого часу має вирішальне значення для точного прогнозування ЧР. Оскільки LSTM і GRU вирішують проблему зникаючого градієнту, це дозволяє їм фіксувати довгострокові залежності в даних ЧР, що є ключовим фактором у завданнях прогнозування, коли минула інформація суттєво впливає на майбутні прогнози. Ефективність GRU, LSTM і RNN також можна

пояснити їхньою архітектурою, яка включає настроюванні параметри для кращого узгодження з характеристиками конкретних даних ЧР. Незважаючи на те, що ці моделі продемонстрували чудові результати, їх практичне впровадження може вимагати ретельного розгляду таких факторів, як складність моделі, час навчання та обчислювальні ресурси. Залежно від конкретного застосування може існувати компроміс між продуктивністю моделі та обчислювальною ефективністю.

**Висновки та напрямок подальших досліджень.** Одним із напрямів, який варто дослідити у сфері аналізу ЧР, є удосконалення архітектур та оптимізація параметрів моделей, зокрема GRU та LSTM, для забезпечення кращої адаптації до різноманітних типів ЧР. Додатково, важливим аспектом є розробка нових методів автоматичного підбору параметрів та архітектур, що дозволить зменшити необхідність експертного втручання та поліпшити ефективність моделей у різних доменних областях. Впровадження таких методів також може полегшити процес роботи з недостатньою кількістю даних. Інший важливий напрямок досліджень – це вдосконалення алгоритмів навчання, зокрема з використанням передових технік навчання з підкріпленням для покращення якості прогнозів та ефективності нейронних мереж. В свою чергу дослідження в області інтеграції нейронних мереж з іншими методами аналізу ЧР, такими як статистичні та фізично засновані підходи, може призвести до створення гібридних моделей, які поєднують вигоди різних методів та забезпечують більшу стійкість та точність. Зосередження на вивченні можливостей ефективного використання даних в реальному часі та адаптації моделей до динамічних змін у середовищі може розширити сферу застосування нейронних мереж у великому обсязі завдань, таких як управління ризиками, інтелектуальне прогнозування та оптимізація бізнес-процесів.

#### *Список літератури*

1. Берзлев, О. Ю. (2013). Сучасний стан інформаційних систем прогнозування часових рядів. Управління розвитком складних систем, (13), 78-82.
2. Kose, U., Arslan, A. (2018). Time series prediction with a hybrid system formed by artificial neural network and cognitive development optimization algorithm. Scientia Iranica, 26, 942-958. <https://doi.org/10.24200/SCI.2018.20033>.
3. Wang, K. (2020). Artificial intelligence algorithm for optimal time series data model. IEEE Access. <https://doi.org/10.1109/access.2020.2981488>.
4. Che, Z., Purushotham, S., Cho, K., Sontag, D., Liu, Y. (2016). Recurrent Neural Networks for Multivariate Time Series with Missing Values. Scientific Reports, 8. <https://doi.org/10.1038/s41598-018-24271-9>.
5. Cinar, Y., Mirisae, H., Goswami, P., Gaussier, É., Ait-Bachir, A. (2018). Period-aware content attention RNNs for time series forecasting with missing values. Neurocomputing, 312, 177-186. <https://doi.org/10.1016/j.neucom.2018.05.090>.
6. Lei, J., Liu, C., Jiang, D. (2019). Fault diagnosis of wind turbine based on Long Short-term memory networks. Renewable Energy. <https://doi.org/10.1016/J.RENENE.2018.10.031>.
7. Kim, T., King, B. (2020). Time series prediction using deep echo state networks. Neural Computing and Applications, 1-19. <https://doi.org/10.1007/s00521-020-04948-x>.
8. Єгоров, В. Ю. (2018). Алгоритми глибокого навчання у прогнозуванні часових рядів.
9. Tolvanen, J., Kelly, S. (2010). Integrating models with domain-specific modeling languages., 10:1-10:6. <https://doi.org/10.1145/2060329.2060354>.
10. Liang, H., Song, L., Wang, J., Guo, L., Li, X., Liang, J. (2021). Robust unsupervised anomaly detection via multi-time scale DCGANs with forgetting mechanism for industrial multivariate time series. Neurocomputing, 423, 444-462. <https://doi.org/10.1016/j.neucom.2020.10.084>.
11. Schmidl, S., Wenig, P., Papenbrock, T. (2022). Anomaly detection in time series. Proceedings of the VLDB Endowment. <https://doi.org/10.14778/3538598.3538602>.
12. Liu, S., Zhou, B., Ding, Q., Hooi, B., Zhang, Z., Shen, H., Cheng, X. (2023). Time Series Anomaly Detection With Adversarial Reconstruction Networks. IEEE Transactions on Knowledge and Data Engineering, 35, 4293-4306. <https://doi.org/10.1109/TKDE.2021.3140058>.
13. Zhang, G. (2003). Time series forecasting using a hybrid ARIMA and neural network model. Neurocomputing, 50, 159-175. [https://doi.org/10.1016/S0925-2312\(01\)00702-0](https://doi.org/10.1016/S0925-2312(01)00702-0).
14. Сабат, А. О. (2020). Дослідження методів прогнозування часових рядів криптовалют. Архів кваліфікаційних робіт.
15. Che, Z., Purushotham, S., Cho, K., Sontag, D., Liu, Y. (2016). Recurrent Neural Networks for Multivariate Time Series with Missing Values. Scientific Reports, 8. <https://doi.org/10.1038/s41598-018-24271-9>.

Рукопис подано до редакції 29.02.24