
ВОЛОКОННО-ОПТИЧНІ ТЕХНОЛОГІЇ В ІНФОРМАЦІЙНИХ (INTERNET, INTRANET ТОЩО) ТА ЕНЕРГЕТИЧНИХ МЕРЕЖАХ

УДК 681.5 : 004.67

О. А. ПОПЛАВСЬКИЙ, О. І. СОРОКА, М. О. ЛІТВІН, А.В. ПОПЛАВСЬКИЙ

ІНТЕЛЕКТУАЛЬНІ СИСТЕМИ УПРАВЛІННЯ РИЗИКАМИ НА ЄВРОПЕЙСЬКИХ ЕНЕРГЕТИЧНИХ РИНКАХ

Київський національний університет будівництва та архітектури, 03680, проспект Повітряних Сил, 31, м.Київ, Україна, e-mail: apoplavskiy@gmail.com

Вінницький національний технічний університет, 21021, Хмельницьке шосе, 95, м. Вінниця, Україна

Міжнародний університету бізнесу і права, 54007, проспект Героїв України, 9, м. Миколаїв, Україна

Анотація. На основі алгоритмів машинного навчання запропоновано метод прогнозування ризиків на європейських енергетичних ринках. Робота спрямована на розробку інтелектуальних систем управління ризиками, які використовують передові технології штучного інтелекту для оцінки та мінімізації потенційних загроз. Використовуючи історичні дані та актуальні тренди ринку, представлено комплексний підхід до визначення цінової волатильності ризикованих зон на енергетичних ринках. Дослідження демонструє, як штучний інтелект може підвищити ефективність рішень, прийнятих керівниками на енергетичних ринках, та забезпечити більш стійке управління ресурсами в умовах зростаючої невизначеності. Результати показують, що використання комплексних алгоритмів машинного навчання та аналізу даних може значно підвищити точність прогнозування ризиків та сприяти прийняттю обґрунтованих управлінських рішень.

Ключові слова: ШІ, РДН, ВДР, спотовий ринок, ф'ючерсний ринок, системи управління, ризиками, прогнозування, великі дані, нейронні мережі.

Abstract. Abstract. Based on machine learning algorithms, a method for predicting risks in the European energy markets has been proposed. The work is aimed at developing intelligent risk management systems that utilize advanced artificial intelligence technologies for assessing and minimizing potential threats. Utilizing historical data and current market trends, a comprehensive approach to identifying price volatility and risk zones in the energy markets is presented. The study demonstrates how artificial intelligence can enhance the effectiveness of decisions made by managers in the energy markets and ensure more sustainable resource management in conditions of increasing uncertainty. The results show that the use of complex machine learning algorithms and data analysis can significantly improve the accuracy of risk prediction and contribute to the adoption of well-founded managerial decisions.

Key words: AI, DAM, spot market, futures market, management systems, risk, forecasting, big data, neural networks.

DOI: 10.31649/1681-7893-2024-47-1-233-239

ВСТУП

У сучасному світі, де енергетичні ринки зазнають швидких змін і нових викликів, управління ризиками стає вирішальним для забезпечення стабільності, ефективності та надійності[1]. Європейські енергетичні ринки, будучи одними з найбільш динамічних і інтегрованих у світі, потребують особливого підходу до управління ризиками, що враховує їх унікальну структуру, регуляторні рамки та взаємозалежності[2]. В цьому контексті інтелектуальні системи управління ризиками, які включають в себе штучний інтелект (ШІ), машинне навчання та великі дані, відіграють ключову роль, пропонуючи новітні рішення для ідентифікації, аналізу та мінімізації потенційних ризиків.

ВОЛОКОННО-ОПТИЧНІ ТЕХНОЛОГІЇ В ІНФОРМАЦІЙНИХ (INTERNET, INTRANET ТОЩО) ТА ЕНЕРГЕТИЧНИХ МЕРЕЖАХ

Дана робота розглядає потенціал застосування інтелектуальних систем управління ризиками на прикладі одного з європейських енергетичних ринків, пропонуючи один з сучасних підходів який, на думку авторів має великий потенціал для застосування[3]. Зокрема, розглядаються випадки комплексного використання алгоритмів прогнозування, оптимізації, автоматизації процесів та підвищення точності обробки даних, що разом сприяють підвищенню ефективності управління ризиками на енергетичних ринках.

Актуальність теми впливає з невідомих змін у глобальному енергетичному міксі та зростаючої залежності від стійких енергетичних систем. В умовах збільшення частки відновлювальних джерел енергії та необхідності інтеграції цих джерел у традиційні енергосистеми, ризики стають все більш складними і непередбачуваними. Ці зміни вимагають від учасників ринку та регуляторів адаптації до нових умов і викликають потребу у впровадженні передових технологій для ефективного реагування на потенційні загрози.

Інтелектуальні системи, які аналізують великі обсяги даних, дозволяють прогнозувати ринкові коливання, оцінювати ризики збоїв у постачанні, та оптимізувати роботу енергетичних систем в реальному часі. Розвиток цих технологій може кардинально змінити методи управління ризиками, роблячи їх більш автоматизованими, ефективними та адаптивними до змін у зовнішніх умовах.

Використання інтелектуальних систем відкриває нові можливості для зменшення впливу негативних подій на енергетичний ринок, забезпечуючи таким чином більшу стабільність та надійність енергопостачання в регіоні. Також це сприяє підвищенню прозорості ринку, що є важливим для врахування інтересів усіх зацікавлених сторін, включаючи споживачів, інвесторів, та урядові структури.

ВИКОРИСТАННЯ ВЕЛИКИХ ДАНИХ ДЛЯ ПРОГНОЗУВАННЯ ІНДЕКСІВ НА РИНКАХ ЕНЕРГОРЕСУРСІВ

У контексті ринків енергоресурсів, де волатильність та непередбачуваність виступають як основні фактори ризику, аналіз великих даних і прогнозування індексів набуває вирішального значення. Використання великих обсягів даних дозволяє інтелектуальним системам управління ризиками на ринках енергоресурсів забезпечувати високий рівень точності прогнозів, оптимізувати процеси прийняття рішень та зміцнювати стабільність енергетичної системи.

Використання великих даних у прогнозуванні індексів на ринках енергоресурсів базується на обробці величезних масивів інформації, яка включає історичні дані про ціни, попит, пропозицію, погодні умови, політичні та економічні індикатори. Ці дані дозволяють ідентифікувати тенденції та закономірності, які людиною або традиційні методи аналізу не змогли б виявити без застосування складних алгоритмів. Отже, інтелектуальні системи, які аналізують ці дані, здатні генерувати прогнози з високою точністю, що критично важливо для управління ризиками і оптимізації роботи енергетичних ринків [4].

Для обробки великих даних та створення прогнозних моделей використовуються різноманітні інструменти машинного навчання, але одними з найбільш ефективних є нейронні мережі. Ці мережі імітують механізми обробки інформації в мозку людини, що дозволяє їм вчитися на основі досвіду, адаптуватися до нових умов і робити обґрунтовані передбачення на основі великих і складних даних. Застосування нейронних мереж на ринках енергоресурсів особливо доцільне, оскільки вони можуть ефективно обробляти неструктуровані дані, виявляти складні залежності в даних та генерувати прогнози, що мінімізують ризики та підвищують ефективність управління ресурсами [5].

Використання нейронних мереж для цілей розпізнавання патернів та класифікації продемонструвало високу ефективність у роботах[6-8], завдяки здатності адаптивно оптимізувати вагові коефіцієнти в процесі навчання, що дозволяє виявляти складні залежності в даних та вирішувати завдання з високою точністю, навіть у умовах змінних та неструктурованих вхідних даних. Модифікація самої мережі, зміна схеми з'єднань або застосування попередньої обробки даних може значно підвищити продуктивність нейронних мереж [9-10].

МОДИФІКАЦІЯ НЕЙРОННИХ МЕРЕЖ ДЛЯ ІНТЕЛЕКТУАЛЬНИХ СИСТЕМ ПІДТРИМКИ ПРИЙНЯТТЯ РІШЕНЬ НА ЕНЕРГЕТИЧНИХ РИНКАХ

У контексті використання нейронних мереж для інтелектуальних систем підтримки прийняття рішень на енергетичних ринках, першочерговою задачею є детальний аналіз та підготовка вхідних даних, що використовуються для навчання та прогнозування [11]. Важливість цього процесу обумовлена безпосереднім впливом якості підготовлених даних на точність та надійність прогнозних моделей. Процес розробки включає в себе кілька ключових етапів:

ВОЛОКОННО-ОПТИЧНІ ТЕХНОЛОГІЇ В ІНФОРМАЦІЙНИХ (INTERNET, INTRANET ТОЩО) ТА ЕНЕРГЕТИЧНИХ МЕРЕЖАХ

- Підготовка даних включає вибірку необхідних даних для навчання та їх подальшу нормалізацію, що включає оцінку релевантності, очищення від помилок та аномалій, а також приведення масштабів різних даних до єдиної нормованої форми.
- Розробка архітектури нейромережі полягає у визначенні структури мережі, виборі кількості шарів і нейронів у кожному з них, а також у виборі функцій активації.
- Навчання нейромережі здійснюється за допомогою алгоритмів прямого та зворотного поширення помилок, що дозволяє адаптувати ваги нейронів у відповідності з прогнозованими помилками.
- Тестування та оцінка моделі включає використання валідаційних і тестових наборів даних для оцінки якості прогнозів та здатності моделі до узагальнення [12].

Необхідно визначити цільові змінні для прогнозування та параметри нейромережі, включаючи кількість шарів, нейронів у кожному шарі, типи функцій активації, швидкість навчання, кількість епох та інші гіперпараметри для ефективного навчання нейромережі та рішення задач, що ставляться перед нею [9].

Збір даних для дослідження здійснювався з визначення ключових джерел інформації, які включали національні енергетичні платформи та організації. Було використано веб-сайти таких установ, як АТ "Оператор ринку" та НЕК "Укренерго", де регулярно публікується актуальна інформація про ціни на електроенергію, попит і пропозицію, а також транзакції на ринку. Окрім того, використовувалась інформація Української енергетичної біржі для збору даних про торгівлю енергоресурсами. Ці джерела дозволили отримати доступ до великої кількості статистичних даних, необхідних для подальшого аналізу.

Автоматизація процесу збору даних здійснювалась за допомогою скриптів на мові Python, які були написані для вилучення даних з цих веб-сайтів в режимі реального часу. Застосування Python дозволило використовувати потужні бібліотеки для веб-скрапінгу, такі як BeautifulSoup та Scrapy, а також Pandas для обробки і аналізу структурованих даних. Ці інструменти сприяли швидкому та точному вилученню інформації, перетворенню її у потрібні формати і підготовці до подальшого аналізу.

Такий підхід не тільки забезпечив надійність і актуальність даних, але й значно знизив час, необхідний для їх обробки та аналізу, дозволяючи фокусуватися на розробці стратегій і прогнозів, заснованих на точній інформації.

Таким чином, завдяки автоматизованому збору даних за допомогою скриптів Python, було отримано агреговану базу даних. Ця база складалася з актуальної та ретельно структурованої інформації, зібраної з різних джерел. Отримані дані включали інформацію про транзакції на енергетичному ринку, ціни, попит та пропозицію, що було надзвичайно важливо для подальшої аналітичної роботи.

На основі цієї агрегованої бази даних була розроблена архітектура нейронної мережі, яка мала на меті швидко прогнозування параметрів дані часових рядів, що передаються до вхідного шару нейромережі. В основі архітектури лежить класична повнозв'язна штучна нейронна мережа, що складається з вхідного шару, двох прихованих шарів та вихідного шару. Вхідний шар приймає дані часових рядів, що включають інформацію за п'ять днів, перетворюючи їх у тензори з 4752 нейронами (144 години * 33 параметри).

Метод, запропонований у даному дослідженні, базується на використанні лінійної регресії для прогнозування, використовуючи історичний набір даних з 30 значень для визначення майбутніх тенденцій. Ця методика дозволяє моделі інтерполювати можливі наступні значення, базуючись на лінійній залежності від попередніх спостережень:

$$Y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n + \epsilon, \quad (1)$$

де Y – прогнозоване значення, x_i – вхідні параметри, β_i – коефіцієнти лінійної регресії, а ϵ – випадкова помилка.

Важливим елементом методології є застосування оптимізатора Adam, який дозволяє ефективно налаштовувати ваги в нейромережі, адаптуючи швидкість навчання для кожного параметра ваги окремо:

$$\theta_{t+1} = \theta_t - \frac{\alpha}{\sqrt{\partial_{t+\epsilon}}} \hat{m}_t, \quad (2)$$

де θ_t – параметри моделі в момент t , α – швидкість навчання, \hat{m}_t – оцінки перших і других моментів градієнтів, а ϵ – дуже мале число, що запобігає діленню на нуль.

Швидкість навчання була встановлена на рівні 0.0001, що забезпечує оптимальний баланс між швидкістю навчання та стабільністю процесу. В якості функції втрати використовується MSELoss, яка ефективно корегує модель при великих відхиленнях у прогнозах:

$$L(\theta) = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i(\theta))^2, \quad (3)$$

де $L(\theta)$ – втрата за функцією MSELoss, N – кількість спостережень, y_i – реальні значення, а $\hat{y}_i(\theta)$ – прогнозовані значення.




Рисунок 1 – Приклад архітектури нейронної мережі, яка використовує швидке прогнозування параметрів дані часових рядів методом лінійної регресії.

В рамках експериментального дослідження були застосовані розроблені алгоритми та методи до реальних даних, щоб перевірити ефективність розроблених методів. Початковим етапом дослідження розроблених методів та інструментів був процес підготовки, який вимагав завантаження необхідних інструментів аналізу.

У цьому контексті було завантажено бібліотеки, що використовуються для обробки даних та побудови моделей машинного навчання, зокрема, Pandas для аналізу даних, PyTorch з модулями nn для створення архітектури мережі, F для активаційних функцій, та optim для оптимізації параметрів нейронної мережі, а також matplotlib для візуалізації результатів.

Завантаження даних з Excel файлу здійснювалося за допомогою функції read_excel() від бібліотеки Pandas, що дозволило імпортувати дані у форматі DataFrame, з яким легко працювати в Python. Після завантаження файлу, виведення інформації про кількість рядків та стовпців дало розуміння що розмір датасету коректний, вказуючи на коректність відкриття бази даних і подальші можливі дії з остаточною перевіркою даних на цілісність та перетворення типів даних для відповідності до вимог аналітичних методів.

Для здійснення обґрунтованого порівняння розроблених методів прогнозування з сучасними підходами, спочатку було необхідно отримати результати обробки великих даних за допомогою стандартних навчених нейронних мереж. Цей крок передбачав використання класичної архітектури нейронної мережі, яка вже показала свою ефективність в аналогічних завданнях аналізу[2].

З описаною архітектурою нейронної мережі було проведено навчання мережі та прогнозування даних для останніх доступних повних 7 місяців, визначивши фактичні середні втрати на тестових даних відповідних місяців.

Тренування цих мереж здійснювалося на однакових великих наборах даних, забезпечуючи умови для точного порівняння. Оцінка ефективності здійснювалася за такими параметрами, як точність прогнозування, час обробки даних та здатність узагальнювати на нових даних, не бачених моделлю під час тренування.

Результати, отримані запропонованим методом, демонструють потенціал для використання у прогнозуванні на ринках електроенергії. Оптимізація гіперпараметрів, включаючи розміри шарів, швидкість навчання, кількість епох та інші параметри моделі, була виконана на основі численних експериментів та аналізу даних від тренування та валідації.

ВОЛОКОННО-ОПТИЧНІ ТЕХНОЛОГІЇ В ІНФОРМАЦІЙНИХ (INTERNET, INTRANET ТОЩО) ТА ЕНЕРГЕТИЧНИХ МЕРЕЖАХ

06 Epoch тренування 20, Середня втрата: 24819.298271755142 Середня втрата на тестових даних: 21027.996594955523
 07 Epoch тренування 20, Середня втрата: 25024.88083105217 Середня втрата на тестових даних: 452637.6972737466
 08 Epoch тренування 20, Середня втрата: 32462.81801865983 Середня втрата на тестових даних: 102435.28373176821
 09 Epoch тренування 20, Середня втрата: 33659.31687124984 Середня втрата на тестових даних: 234064.42955347698
 10 Epoch тренування 20, Середня втрата: 36317.043575311625 Середня втрата на тестових даних: 270244.43057472474
 11 Epoch тренування 20, Середня втрата: 40582.98926941536 Середня втрата на тестових даних: 545073.4616212209
 12 Epoch тренування 20, Середня втрата: 42951.239968864815 Середня втрата на тестових даних: 271600.7446761593

Рисунок 2 – Результати роботи скрипта по прогнозуванню даних для останніх доступних повних семи місяців

Застосування цієї моделі до реальних даних показало, що вона може з високою точністю (з похибкою до 4% в стабільні місяці за деякими параметрами) прогнозувати ключові індикатори, такі як ціни, попит та пропозиція на електроенергію у різні часові періоди. Візуалізація прогнозів порівняно з реальними даними вказує на тісну відповідність між прогнозованими та фактичними показниками, що підтверджує адекватність моделі відображення динаміки ринку.

Низькі втрати на тренувальних та тестових наборах даних свідчать про відсутність перенавчання та здатність моделі узагальнювати на нових даних, що є критично важливим для адаптивності моделі в змінних умовах ринку електроенергії.

	Прогноз	Факт	Середнє відхилення	
1	2917,77	2934,2754	16,50585938	0,56%
2	2963,888	2859,9099	103,9785156	3,64%
3	2882,156	2928,5017	46,34619141	1,58%
4	2885,337	2792,2429	93,09375	3,33%
5	2862,971	2994,325	131,3540039	4,39%
6	3003,999	2961,9458	42,0534668	1,42%
7	3070,829	2994,4453	76,38354492	2,55%
8	2976,092	3050,6567	74,56469727	2,44%
9	2998,551	3005,2942	6,743164063	0,22%
10	2998,525	2887,4263	111,098877	3,85%
11	2921,635	2974,2288	52,59375	1,77%
12	2987,655	3276,0962	288,4416504	8,80%
13	3025,558	3333,3333	307,7749023	9,23%
14	3048,174	2725,7954	322,3786621	11,83%

Місяць	Абс.похибка	Відсоток
6	0,11	3,84%
7	0,52	17,50%
8	0,26	6,55%
9	0,39	11,79%
10	0,42	11,74%
11	0,65	15,72%
12	0,43	13,38%
Сер. зн	0,40	11,50%

Рисунок 3 – Прогнозні результати для базового навантаження ціни на РДН за обраний період

Похибка прогнозування моделі, визначена за стандартними метриками, показала низький рівень помилок (11,5%), свідчаючи про надійність моделі. Це робить її придатною для використання в аналітичних відділах енергетичних компаній, трейдерами, та в автоматизованих системах купівлі та продажу електроенергії. Дослідження також виявило, що удосконалена модель нейронної мережі з механізмом швидкого прогнозування видає кращі результати, ніж базова модель, завдяки глибшим аналітичним функціям для точного прогнозування критичних ринкових індикаторів. Інтеграція швидкого прогнозування дозволяє моделі ефективніше адаптуватися до змін у даних і з вищою точністю прогнозувати коливання на ринку. Ефективність моделей порівнювалася за параметром середньої втрати на тестових даних, де втрати визначалися за допомогою MSE (Mean Squared Error).

Підтвердження результатів дослідження включало застосування додаткової методики прогнозування – лінійної регресії, яка є загальноприйнятою в класичних статистичних дослідженнях і служить стандартом для порівняльного аналізу.

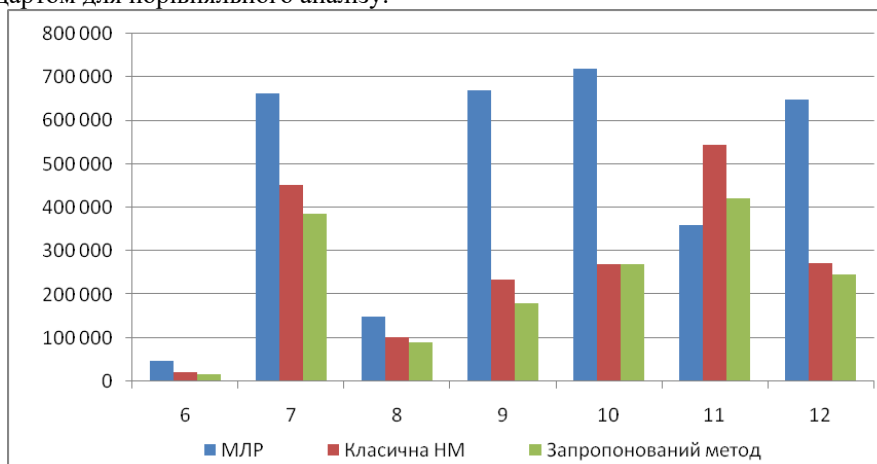


Рисунок 4 – Порівняльний аналіз середніх втрат на тестових даних за різними методами прогнозування.

ВОЛОКОННО-ОПТИЧНІ ТЕХНОЛОГІЇ В ІНФОРМАЦІЙНИХ (INTERNET, INTRANET ТОЩО) ТА ЕНЕРГЕТИЧНИХ МЕРЕЖАХ

На рис. 4 зображено, як метод прогнозування на основі нейронних мереж значно випереджає традиційний метод лінійної регресії, особливо при аналізі великих обсягів даних, які містять складні нелінійні залежності. Метод, представлений у дослідженні, який передбачає швидке прогнозування параметрів, продемонстрував ще кращі показники порівняно з традиційною нейромережевою моделлю. Середньомісячна втрата на тестових даних була знижена більш ніж на 15%, що свідчить про значне покращення. Це підтверджує ефективність розробленої моделі та її спроможність проводити глибокий аналіз та ідентифікацію закономірностей у даних, забезпечуючи точне прогнозування у динамічних умовах ринку електроенергії.

Оцінка швидкості методів є важливим аспектом у визначенні ефективності методів прогнозування, поряд із точністю. Швидкість методу прогнозування залежить від кількох чинників, включаючи складність моделі, обсяг даних та обчислювальні ресурси, які використовуються для тренування і валідації моделі. Традиційні нейромережі, незважаючи на високу точність, часто вимагають значних обчислювальних ресурсів та часу для навчання, особливо при роботі з великими даними.

У проведеному дослідженні час відкриття бази даних є статичним параметром і становить 11026,5 мс. для всіх трьох аналізованих методів. Цей параметр визначає загальний час, необхідний для ініціалізації та підготовки даних до обробки, слугуючи індикатором ефективності системи у взаємодії з великим обсягом даних.

Таблиця 1

Час виконання відповідних алгоритмів

Замір часу в сек.	Лінійна Регресія	Класична НМ	Запропонований метод
Відкриття бази даних	11,0265	11,0265	11,0265
Середній час створення 1го тренувального набору даних	0,0001	0,0002	0,5008
Створення нейромережі	-	0,0029	0,0030
Навчання нейромережі (1 епоха)	-	4,5339	5,0935
Збереження ваг нейромережі	-	0,0032	0,0040
Отримання прогнозованого значення	0,00025	0,00017	0,00018
Візуалізація результатів	0,0950	0,0950	0,0950

Оцінка середнього часу створення тренувального набору даних виявила схожість між лінійною регресією та класичною нейромережею з часовими показниками 0,1 та 0,2 мс відповідно, що свідчить про аналогічність алгоритмічних процедур у цих методах. Проте, запропонований метод вимагає значно більше часу (500,8 мс.), обумовлене необхідністю швидкого прогнозування параметрів. Час створення самої нейромережі мало відрізняється між класичною та новою моделлю, становлячи 2,9 та 3 мс відповідно, що вказує на невелике розширення структури в новому методі.

За одну епоху навчання нейромережі, класичний метод показав час 4533,9 мс, тоді як новий метод зайняв 5935 мс, що свідчить про вищі часові витрати нового методу через додаткові обчислення зі збільшеними даними. Процес збереження ваг нейромережі також показав незначні різниці, з 3,2 мс для класичної мережі проти 4 мс для нового методу.

Час отримання прогнозованого значення після навчання між методами майже ідентичний, становлячи 0,17 та 0,18 мс відповідно. Незначна додаткова часова витрата в 0,01 мс для нового методу виправдана значним поліпшенням точності прогнозування. Ці дані підтверджують, що новий метод має значний потенціал для застосування в реальних умовах на ринках електроенергії, де точність прогнозування є ключовою для успішного прийняття рішень, надаючи аналітикам, трейдерам та іншим фахівцям важливі дані для оптимізації стратегій купівлі та продажу.

ВИСНОВКИ

Процес апробації запропонованого методу на різних наборах даних продемонстрував його універсальність та надійність. Особливо важливим було виявлення здатності методу ефективно обробляти статистичні дані, що включає розпізнавання складних закономірностей між числовими показниками. Додатково, методи продемонстрували ефективність у виявленні аномалій, що предметом подальших досліджень.

Експерименти підтвердили теоретичні припущення, що лягли в основу розробки запропонованого методу, і продемонстрували високу точність прогнозування та класифікації при роботі з різними типами даних. Таке підтвердження вказує на ефективність розроблених технічних рішень для практичного застосування.

Враховуючи результати експериментів, можна зробити висновок, що розроблений метод та інструменти вносять значний внесок у вдосконалення процесів обробки даних і можуть служити як

ВОЛОКОННО-ОПТИЧНІ ТЕХНОЛОГІЇ В ІНФОРМАЦІЙНИХ (INTERNET, INTRANET ТОЩО) ТА ЕНЕРГЕТИЧНИХ МЕРЕЖАХ

надійна основа для подальших наукових досліджень та розробки нових технічних рішень в області великих даних.

СПИСОК ЛІТЕРАТУРИ / REFERENCES

1. Lin, J., Jia, S., & Deng, J. (2017). *Smart risk management with financial big data*. 2017 IEEE/SICE International Symposium on System Integration (SII). DOI:10.1109/SII.2017.8279189
2. Karthik V, K. (2023). Applications of Machine Learning in Predictive Analysis and Risk Management in Trading. *International Journal of Innovative Research in Computer Science and Technology*. DOI: 10.55524/ijrcst.2023.11.6.4.
3. Aziz, S., & Dowling, M. (2018). Machine Learning and AI for Risk Management. *Disrupting Finance*. DOI: 10.1007/978-3-030-02330-0_3
4. Fei Wu, Dayong Zhang, Qiang Ji. (2021). Systemic risk and financial contagion across top global energy companies. *Energy Economics*, 97, 105221. DOI: 10.1016/J.ENECO.2021.105221
5. M. Naeem, Faruk Balli, S. Shahzad, A. Bruin. (2020). Energy commodity uncertainties and the systematic risk of US industries. *Energy Economics*, 85, 104589. DOI: 10.1016/j.eneco.2019.104589
6. Li, R.-P., Mukaidono, M., & Turksen, I. B. (2002). A fuzzy neural network for pattern classification and feature selection. *Fuzzy Sets and Systems*, 130(1), 101-108. DOI: 10.1016/S0165-0114(02)00050-7
7. Giacinto, G., & Roli, F. (2001). Design of effective neural network ensembles for image classification purposes. *Image and Vision Computing*, 19(9-10), 699-707. DOI: 10.1016/S0262-8856(01)00045-2
8. Arsenault, H.H., Sheng, Y., Jouan, A., & Lejeune, C. (1988). Improving The Performance Of Neural Networks. *Photonics West - Lasers and Applications in Science and Engineering*. DOI:10.1117/12.944103
9. Poplavskyi, Oleksandr. (2024). Modern methods of risk management in Ukrainian energy markets. *Management of Development of Complex Systems*
10. Cho, S.-B. (1999). Pattern recognition with neural networks combined by genetic algorithm. *Fuzzy Sets and Systems*, 103(1), 339-347. DOI: 10.1016/S0165-0114(98)00232-2
11. Kaklauskas, A., Dzemyda, G., Tupėnaitė, L., Voitau, I., Kurasova, O., Naimaviciene, J., Rassokha, Y., & Kanapeckiene, L. (2018). Artificial Neural Network-Based Decision Support System for Development of an Energy-Efficient Built Environment. *Energies*, 11(8), 1994. DOI: 10.3390/EN11081994
12. Pinto, T., Sousa, T., Praça, I., Vale, Z., & Morais, H. (2016). Support Vector Machines for decision support in electricity markets' strategic bidding. *Neurocomputing*, 172, 438-445. DOI: 10.1016/j.neucom.2015.03.102.

Надійшла до редакції 7.05.2024 р.

ПОПЛАВСЬКИЙ ОЛЕКСАНДР АНАТОЛІЙОВИЧ – к.т.н., доцент, доцент кафедри інформаційних технологій, Київський національний університет будівництва і архітектури, Київ, Україна,
e-mail: apoplavskyi@gmail.com

СОРОКА ОЛЕКСАНДР ІГОРОВИЧ – молодший науковий співробітник Науково-дослідного інституту проблем архітектурно-будівельної екології (НДІ ПАБЕ), Київський національний університет будівництва і архітектури, Київ, Україна, ***e-mail: sasha.soroka1997ua@gmail.com***

ЛІТВІН МИХАЙЛО ОЛЕКСАНДРОВИЧ – студент Міжнародного університету бізнесу і права, Миколаїв, Україна, ***e-mail: mihailitvinc@gmail.com***

ПОПЛАВСЬКИЙ АНАТОЛІЙ ВАЦЛАВОВИЧ – к.т.н., доцент, доцент кафедри менеджменту та безпеки інформаційних систем, Вінницький національний технічний університет, Вінниця, Україна,
e-mail: avpoplavskiy60@gmail.com

O.A. POPLAVSKYI, O.I. SOROKA, M.O. LITVIN, A.V. POPLAVSKYI
INTELLIGENT RISK MANAGEMENT SYSTEMS IN EUROPEAN ENERGY MARKETS
Kyiv National University of Construction and Architecture,
Vinnitsia National Technical University,
International University of Business and Law