

**МІНІСТЕРСТВО ОСВІТИ І НАУКИ УКРАЇНИ
ЗАПОРІЗЬКИЙ НАЦІОНАЛЬНИЙ УНІВЕРСИТЕТ
ЕКОНОМІЧНИЙ ФАКУЛЬТЕТ
КАФЕДРА ЕКОНОМІЧНОЇ КІБЕРНЕТИКИ**

**Кваліфікаційна робота
магістра**

на тему **ЗАСТОСУВАННЯ НЕЙРОМЕРЕЖНОГО МОДЕЛЮВАННЯ ДЛЯ
ПРОГНОЗУВАННЯ ДИНАМІКИ ПРОДАЖІВ НА РИНКУ
ЕЛЕКТРОМОБІЛІВ**

Виконав: студент II курсу, групи 8.0512–ек-з
спеціальності 051 «Економіка»
освітньої програми «Економічна кібернетика»
Штурмак Євгеній Валерійович
Керівник зав. каф. ек.кіб., д.е.н, професор
Макшишко Н.К.
Рецензент: доцент каф. ек.кіб., к.е.н, доцент
Макаренко О.І.

Запоріжжя
2023

6. Консультанти розділів роботи

Розділ	Прізвище, ініціали та посада консультанта	Підпис, дата	
		завдання видав	завдання прийняв
Розділ 1	д.е.н. проф. Максишко Н.К.		
Розділ 2	д.е.н. проф. Максишко Н.К.		
Розділ 3	д.е.н. проф. Максишко Н.К.		

7. Дата видачі завдання 18.09.2023

КАЛЕНДАРНИЙ ПЛАН

№ з/п	Назва етапів кваліфікаційної роботи	Строк виконання етапів роботи	Примітка
1.	Формування мети та завдань кваліфікаційної роботи	18.09-23.09.2023	
2.	Складання плану роботи	25.09-30.09.2023	
3.	Підготовка I розділу	02.10-21.10.2023	
4.	Підготовка II розділу	23.10-04.11.2023	
5.	Підготовка III розділу	06.11-26.11.2023	
6.	Оформлення висновків та роботи	27.11-30.11.2023	
7.	Підготовка до захисту і нормоконтролю	28.11-01.12.2023	

Студент _____ Штурмак Є. В.
(підпис)

Керівник роботи (проекту) _____ Максишко Н.К.
(підпис)

Нормоконтроль пройдено

Нормоконтролер _____ Макаренко О.І.

РЕФЕРАТ

Кваліфікаційна робота магістра містить три розділи, 87 с., 35 рис., 3 табл., 41 джерела.

Об'єкт дослідження – динаміка продажів на ринку електромобілів.

Предмет дослідження – нейромережеве моделювання як засіб прогнозування динаміки продажів на ринку електромобілів.

Мета роботи – удосконалення інструментарію прогнозування динаміки продажів на ринку електромобілів шляхом застосування засобів нейромережевого моделювання з врахуванням особливостей архітектури штучних нейронних мереж.

Методи дослідження – аналіз, порівняння і групування даних, узагальнення і систематизація, кластерний аналіз, нейромережеве моделювання.

У роботі аналізується поточний стан електромобільного ринку на світовому рівні, розглядаються наявні проблеми та перешкоди, що ускладнюють подальший розвиток екологічно орієнтованого транспорту в економічному, політичному, технічному та екологічному вимірах. Проведено порівняльний аналіз існуючих інструментів прогнозування та нейромережевих архітектур, спрямованих на прогнозування та класифікацію. Проаналізовано архітектури, які використовуються в даний час для роботи з часовими рядами для задач прогнозування та кластеризації. На основі цього аналізу розроблено нейромережеву модель ансамблевого типу для аналізу та прогнозування динаміки продажів на ринку електромобілів з можливістю її модифікації для застосування в інших галузях. В результаті розроблено рекомендації щодо використання апарату нейронних мереж для побудови моделей прогнозування динаміки продажів на ринку електромобілів.

РИНОК ЕЛЕКТРОМОБІЛІВ, ШТУЧНА НЕЙРОННА МЕРЕЖА, НЕЙРОМЕРЕЖЕВЕ МОДЕЛЮВАННЯ, АРХІТЕКТУРА НЕЙРОННОЇ МЕРЕЖІ, КЛАСТЕРНИЙ АНАЛІЗ, ПРОГНОЗУВАННЯ

SUMMARY

The qualification work of the master contains three sections, 87 pages, 35 figures, 3 tables, 41 sources.

The object of the study is the dynamics of sales in the electric vehicle market.

Subject of research - neural network modeling as a means of forecasting sales dynamics in the electric vehicle market.

The purpose of the study is to improve the tools for forecasting the dynamics of sales in the electric vehicle market by applying neural network modeling tools, taking into account the peculiarities of the architecture of artificial neural networks.

Research methods - scientific analysis, comparison and grouping of data, generalization and systematization, neural network modeling.

The paper analyzes the current state of the electric vehicle market in the global market, considers the existing problems and obstacles that hinder the further development of environmentally friendly transport in the economic, political, technical and environmental dimensions. A comparative analysis of existing forecasting tools and neural network architectures aimed at forecasting and classification is carried out. The architectures that are currently used to work with time series for forecasting and clustering tasks are analyzed. On the basis of this analysis, an ensemble-type neural network model for analyzing and forecasting the dynamics of sales in the electric vehicle market has been developed with the possibility of its modification for use in other industries. As a result, recommendations for using the neural network apparatus to build models for forecasting sales dynamics in the electric vehicle market have been developed.

**ELECTRIC VEHICLE MARKET, ARTIFICIAL NEURAL NETWORK,
NEURAL NETWORK MODELING, NEURAL NETWORK ARCHITECTURE,
CLUSTER ANALYSIS, FORECASTING**

ЗМІСТ

ВСТУП	7
РОЗДІЛ 1 ТЕОРЕТИКО-АНАЛІТИЧНИЙ ОГЛЯД СУЧАСНОГО РИНКУ ЕЛЕКТРОМОБІЛІВ	10
1.1 Загальна характеристика ринку електромобілів.....	10
1.2 Аналіз економічної динаміки розвитку ринку електромобілів.....	16
1.3 Обґрунтування значення ефективного розвитку ринку електромобілів та його прогнозування.....	21
РОЗДІЛ 2 ПРОГНОЗУВАННЯ ЧАСОВИХ РЯДІВ МЕТОДАМИ НЕЙРОМЕРЕЖЕВОГО МОДЕЛЮВАННЯ	26
2.1 Аналіз підходів до прогнозування часових рядів та досвіду прогнозування динаміки продажів на ринку електромобілів.....	26
2.2 Штучні нейронні мережі: сутність та структурна класифікація.....	31
2.3 Основні засади прогнозування методами нейромережевого моделювання.....	36
РОЗДІЛ 3 ЗАСТОСУВАННЯ НЕЙРОМЕРЕЖЕВОГО МОДЕЛЮВАННЯ ДЛЯ ПРОГНОЗУВАННЯ ДИНАМІКИ НА РИНКУ ЕЛЕКТРОМОБІЛІВ.....	46
3.1 Обґрунтування складу та структури вхідних даних для прогнозування динаміки продажів на ринку електромобілів.....	46
3.2 Розробка архітектури штучної нейронної мережі для задачі прогнозування динаміки продажів на ринку електромобілів.....	50
3.3 Результат застосування нейромережевого моделювання та його аналіз.....	58
ВИСНОВКИ.....	74
ПЕРЕЛІК ДЖЕРЕЛ ТА ПОСИЛАНЬ	Ошибка! Закладка не определена.
ДОДАТОК А Характеристики динаміки світового ринку електромобілів ..	82
ДОДАТОК Б Види нейромережевих архітектур	84
ДОДАТОК В Динаміка обсягів продажів електромобілів: Кластер 2.....	85
ДОДАТОК Г Динаміка обсягів продажів електромобілів: Кластер 3.....	87
ДОДАТОК Д Реалізація моделі в Python.....	89

ВСТУП

Щороку у світі зростає актуальність екологічних проблем, зокрема тих, що пов'язані з забрудненням навколишнього середовища, особливо в контексті транспорту. Великі міста з високою щільністю населення стають особливо вразливими до викидів шкідливих речовин, і транспорт є одним з основних джерел забруднення. Ефективність вирішення цієї проблеми частково полягає в переході до використання електромобілів.

Електрокари стають ключовим аспектом стратегічного розвитку як автомобільних компаній, так і об'єктом уваги урядів країн. Перехід до електромобілів є перспективним, хоча його реалізація є складним процесом. Все це й обумовлює актуальність та важливість дослідження розвитку ринку електромобільного транспорту.

У сучасних завданнях прогнозування часових рядів, до яких належить завдання прогнозування динаміки продажів на ринку електромобілів, існує виклик у досягненні ефективних результатів за допомогою традиційних аналітичних методів та методів штучного інтелекту. Застосування звичайних аналітичних методів часто не веде до бажаних результатів через складність сучасних завдань розпізнавання. Методи, що використовують штучний інтелект, не завжди добре пристосовані до великої кількості параметрів, що може виникнути в задачах прогнозування часових рядів. Це може призвести до низького відсотку успішних результатів моделювання, що, в свою чергу, знижує ефективність використання таких моделей. Для подолання цих викликів, вчені використовують глибинне навчання, ансамблеві методи, оптимізацію параметрів, а також врахування контексту та зовнішніх факторів у моделях прогнозування. Ефективність вибору конкретного підходу часто залежить від конкретних особливостей задачі та доступних даних.

Серед різних підходів до прогнозування часових рядів метод, що базується на використанні нейронних мереж, визнається одним з найбільш перспективних. У зв'язку з цим, існує актуальна потреба в подальшому

вдосконаленні моделей прогнозування та алгоритмів, зокрема з використанням різних наборів нейронних мереж. Два ключових критерії оцінювання якості систем прогнозування характеризують їх ефективність. Це швидкість і точність прогнозування.

У зв'язку з цим, дослідники зосереджуються на двох головних напрямках вивчення. По-перше, це поліпшення, оптимізація та розробка нових моделей нейронних мереж для більш точного і надійного прогнозування часових рядів. По-друге, велика увага приділяється вдосконаленню існуючих алгоритмів шляхом використання різних технологій і архітектур процесорів. Це включає в себе застосування новітніх технологій для оптимізації роботи алгоритмів і підвищення їх швидкодії в контексті прогнозування часових рядів.

У сфері прогнозування часових рядів доцільним вважається використання ансамблевих методів та різних архітектур, таких як LSTM, GRU, TCN тощо. Ансамблеві методи дозволяють комбінувати різні моделі для підвищення стабільності та точності прогнозування, зменшуючи ризик перенавчання.

Використання різноманітних архітектур та їх комбінація може забезпечити модель, яка ефективно враховує короткострокові та довгострокові залежності, покращуючи точність прогнозування та загальну надійність системи прогнозування.

Головне завдання при розробці прогнозової моделі у науковому аспекті полягає в ефективному визначенні об'єктів, що визначають ансамблі нейронних мереж. Ці ансамблі сприяють підвищенню загальної здатності нейромереж до узагальнення, зберігаючи при цьому високу ефективність роботи моделі.

Метою роботи є удосконалення інструментарію прогнозування динаміки продажів на ринку електромобілів шляхом застосування засобів нейромережевого моделювання з врахуванням особливостей архітектури штучних нейронних мереж.

Для реалізації мети поставлено та виконано такі завдання:

- проаналізувати поточний стан ринку електромобілів на світовому рівні;
- виявити наявні проблеми та перешкоди, що ускладнюють подальший розвиток екологічно орієнтованого транспорту в економічному, політичному, технічному та екологічному вимірах;
- проаналізувати існуючі інструменти прогнозування та інструментарій нейромережевого програмування;
- здійснити аналіз видів архітектури, які використовуються в даний час для роботи з часовими рядами для задач прогнозування;
- розробити нейромережеву модель для аналізу та прогнозування динаміки продажів на ринку електромобілів;
- розробити рекомендації щодо використання апарату нейронних мереж для побудови моделей прогнозування динаміки продажів на ринку електромобілів.

Наукова і практична новизна кваліфікаційної роботи полягає у розробці та обґрунтуванні нейромережевої моделі ансамблевого типу для аналізу та прогнозування динаміки продажів на ринку електромобілів.

Основні результати дослідження було представлено на:

- XVII Міжнародній науково-практичній конференції "Управління соціально-економічним розвитком регіонів і держави" , м. Запоріжжя, 20-21 квітня 2023 р.;
- IX Всеукраїнський науково-практичній конференції «Сталий розвиток економіки на засадах ресурсоефективності» (м. Запоріжжя, 14-15 грудня 2023 р.

РОЗДІЛ 1

ТЕОРЕТИКО-АНАЛІТИЧНИЙ ОГЛЯД СУЧАСНОГО РИНКУ ЕЛЕКТРОМОБІЛІВ

загальна характеристика ринку електромобілів

Розуміючи важливість автомобілізації для розвитку розвинених країн, можна стверджувати, що наявність конкурентоспроможного автомобільного ринку є важливим фактором для успішного економічного зростання. Загальний аналіз ситуації на світовому ринку автотранспорту вказує на те, що цей сектор переживає процес цифрової трансформації, впроваджуючи нові технології, зокрема в електромобільному сегменті [1]. Зростання попиту на енергію та проблеми, пов'язані з вичерпанням ресурсів та високими цінами на первинні енергоносії, підкреслюють перехід до електромобілів як важливий тренд на ринку транспортних засобів. Наприклад, основне джерело енергії, таке як нафта, стикається з обмеженням своїх ресурсів. Динаміка світових продажів електрокарів представлена в Додатку А, рис. А.1. Розглянемо це питання детальніше.

Це призвело до того, що загальна кількість електромобілів на дорогах світу склала близько 16,5 мільйонів, що втричі більше, ніж у 2018 році. Світові продажі електромобілів продовжували стрімко зростати у 2022 році: у першому кварталі було продано 2 мільйони, що на 75% більше, ніж за аналогічний період 2021 року.

Поступове зниження вартості та збільшення ефективності акумуляторів роблять електромобілі все більш перспективним засобом транспорту. Проте, основним каталізатором зростання світового ринку електромобілів залишається державна підтримка. Наприклад, в Данії в 2016 році відзначився спад продажів електромобілів після скасування податкових пільг для цього виду транспорту [2].

З іншого боку, багато країн продовжують активно підтримувати ринок електромобілів шляхом введення різноманітних стимулів. Крім того, уряди все частіше визначають чіткі терміни для припинення продажів автомобілів з двигунами внутрішнього згоряння на користь електромобілів. Наприклад, у 2017 році Франція та Великобританія оголосили про намір відмовитися від продажу автомобілів з бензиновими та дизельними двигунами до 2040 року, а Великобританія навіть планує заборонити продаж гібридних моделей. Схожі обговорення щодо припинення продажів традиційних автомобілів відбуваються в інших країнах, таких як Норвегія, Нідерланди, Індія та Китай. Ці тенденції роблять електромобілізацію все більш значущим фактором для перегляду прогнозів у сфері енергетики. Експерти визнають, що потенційний вплив електромобілізації на попит на енергоресурси може бути значно великим, ніж їх попередні прогнози [3].

Електрифікація транспорту має багато переваг. Вторгнення Росії в Україну вивело роль електромобілів у скороченні попиту на нафту на перший план. Окрім того, це є одним з 10 заходів, запропонованих Міжнародним енергетичним агентством (International Energy Agency: IEA) [1] для скорочення використання нафти в найближчій перспективі. Розгортання використання електромобілів відповідно до обіцянок та оголошень в Сценарії оголошених зобов'язань (Announced Pledges Scenario – APS), запропонованих IEA, передбачає заміщення (за винятком дво- та триколісних транспортних засобів) 1,6 млн барелів на день (б/д) нафти до 2025 року та 4,6 млн б/д до 2030 року. З точки зору зміни клімату, електромобілі досягають чистого скорочення викидів парникових газів майже на 580 млн. т CO₂-екв в АПС на основі «від свертловини до колеса» порівняно з еквівалентним використанням транспортних засобів з двигуном внутрішнього згоряння (ДВЗ) - це більше, ніж сьогоднішні викиди CO₂, пов'язані з енергією в Канаді. Електрифікація транспорту природно збільшує попит на електроенергію: за прогнозами, до 2030 року в APS на електромобілі припадатиме близько 4% загального кінцевого попиту на електроенергію. На рівні 1 100 терават-годин (ТВт-год)

попит на електроенергію з боку електромобілів у всьому світі у 2030 році в APS еквівалентний повоєнному сьогоднішньому загальному споживанню електроенергії в Бразилії [1].

У сучасний момент глобальний ринок електромобілів переживає період інтенсивного росту, характеризуючись новим «бумом». Швидкі темпи розвитку сприяють вдосконаленню технологій, збільшенню дальності пробігу до 300-400 км на одному заряді, розширенню інфраструктури зарядних станцій. Значимі чинники також включають мотивацію для збереження навколишнього середовища, випуск більш доступних моделей електрокарів та підтримку з боку урядів країн у вигляді субсидій для цих технологій. Усе це робить перспективи розвитку цього ринку дуже перспективними.

Уже не один рік міжнародне співтовариство обговорює можливість введення заборони на автомобілі з двигунами внутрішнього згоряння (ДВЗ). Кілька країн перейшли від обговорення до конкретних дій. Наприклад, Норвегія активно фінансує субсидії для покупців електромобілів і надає їх власникам можливість безкоштовного проїзду по платним автобанам. Крім того, Норвегія встановила заборону на продаж дизельних та бензинових автомобілів з 2025 року. Інші країни, такі як Франція, Німеччина, Нідерланди, Індія та Китай, також висловили свої наміри ввести подібну заборону. Франція, наприклад, планує досягти цілі до 2040 року, тоді як інші країни розглядають терміни від 2030 до 2040 року. Ці ініціативи свідчать про зростаючу глобальну тенденцію до відмови від традиційних автомобілів з двигунами внутрішнього згоряння на користь більш екологічно чистих та стійких технологій.

Прогнози Міжнародного енергетичного агентства (МЕА) вказують, що до 2030 року кількість електромобілів у світі може зрости від 55 до 200 мільйонів одиниць, залежно від сценарію реалізації кліматичної політики. У сценарії "2DS", який передбачає обмеження глобального потепління з 50% ймовірністю на 2°C, парк електромобілів світу перевищить 150 мільйонів одиниць, що становитиме 10% від загального числа легкових автомобілів до

2030 року. До 2060 року цей парк може зрости до 1,2 мільярда одиниць, або 60% від усього автопарку. Аналітики Bloomberg New Energy Finance прогнозують [5], що до 2040 року електромобілі можуть займати 54% ринку нових автомобілів і складати 33% світового автопарку. Ці числа вказують на значний ріст популярності та поширення електромобілів, враховуючи різноманітні сценарії та оцінки розвитку цього ринку.

Так, за даними аналітиків Bloomberg, поширення електромобілів може призвести до значного зменшення попиту на нафту. Прогнозується, що до 2040 року розповсюдження електромобілів може призвести до скорочення попиту на нафту на 8 мільйонів барелів на день. Крім того, ці автомобілі будуть відповідальні за забезпечення 5% глобального попиту на електроенергію [5].

Цей прогноз відображає потенційний вплив електромобілів на енергетичний ринок та демонструє, як зростаюча популярність та впровадження електричних транспортних засобів можуть вплинути на використання паливних ресурсів і структуру глобального попиту на електроенергію.

В сценарії "2DS" Міжнародного енергетичного агентства (МЕА) передбачається, що до 2030 року автопарк електромобілів буде становити до 1,5% від загального попиту на електроенергію. Це буде лише 6% від загального приросту попиту на електроенергію. Очікується, що такий розподіл може призвести до значних технічних викликів в енергетичних системах, особливо великих містах. Для забезпечення стійкості енергетичних систем у таких умовах буде необхідно провести значні трансформації в роботі розподільних мереж. Також, велика увага буде приділена впровадженню систем зберігання енергії та оптимізації пікових навантажень. Ці заходи будуть спрямовані на забезпечення ефективного та стабільного електропостачання при зростанні попиту на електроенергію, яке викликається розширенням автопарку електромобілів.

Стрімке зростання продажів електромобілів під час пандемії перевірило на міцність ланцюги постачання акумуляторів, а війна Росії в Україні ще більше загострила цю проблему. Ціни на сировину, таку як кобальт, літій і нікель, різко зросли. У травні 2022 року ціни на літій були більш ніж у сім разів вищими, ніж на початку 2021 року. Ключовими факторами є безпрецедентний попит на акумулятори та відсутність структурних інвестицій у нові виробничі потужності. Втручання Росії в Україну створило додатковий тиск, оскільки Росія постачає 20% світового високочистого нікелю. У 2021 році середні ціни на акумулятори впали на 6% до 132 доларів США за кіловат-годину, що є повільнішим зниженням, ніж 13% падіння попереднього року. Якщо ціни на метал у 2022 році залишаться такими ж високими, як у першому кварталі, акумуляторні блоки стануть на 15% дорожчими, ніж у 2021 році, за інших рівних умов. Однак, враховуючи поточну кон'юнктуру цін на нафту, відносна конкурентоспроможність електромобілів залишається незмінною.

Сьогодні ланцюги постачання акумуляторів зосереджені навколо Китаю, який виробляє три чверті всіх літій-іонних акумуляторів і є домом для 70% виробничих потужностей з виробництва катодів і 85% виробничих потужностей з виробництва анодів (обидва компоненти є ключовими компонентами акумуляторів). Більше половини потужностей з переробки та рафінування літію, кобальту і графіту розташовані в Китаї [5]. Європа відповідає за понад чверть світового виробництва електромобілів, але вона є домом для дуже малої частини ланцюжка поставок, окрім переробки кобальту на рівні 20%. Сполучені Штати відіграють ще меншу роль у глобальному ланцюжку постачання акумуляторів для електромобілів, маючи лише 10% виробництва електромобілів і 7% потужностей з виробництва акумуляторів. І Корея, і Японія мають значні частки в ланцюжку поставок після переробки сировини, особливо у високотехнологічному виробництві катодних і анодних матеріалів: на Корею припадає 15% потужностей з виробництва катодних матеріалів, а на Японію - 14% виробництва катодних і 11% анодних матеріалів.

Корейські та японські компанії також беруть участь у виробництві інших компонентів акумуляторів, таких як сепаратори.

Видобуток, як правило, відбувається в багатих на ресурси країнах, таких як Австралія, Чилі та Демократична Республіка Конго, і здійснюється кількома великими компаніями. Уряди Європи та США мають сміливі ініціативи в державному секторі щодо розвитку внутрішніх ланцюгів постачання акумуляторів, але більшість ланцюгів постачання, ймовірно, залишатиметься китайською до 2030 року. Наприклад, 70% потужностей з виробництва акумуляторів, заявлених на період до 2030 року, знаходяться в Китаї.

Існують й інші змінні, що впливають на попит на мінерали [1, 6] Якщо нинішні високі ціни на сировину зберуться, катодна хімія може переорієнтуватися на менш мінераломісткі варіанти. Наприклад, літій-залізо-фосфатна хімія не потребує нікелю чи кобальту, але має нижчу щільність енергії, а тому краще підходить для транспортних засобів з меншим запасом ходу. Їх частка у світовому постачанні акумуляторів для електромобілів зросла більш ніж удвічі з 2020 року завдяки високим цінам на мінерали та технологічним інноваціям, насамперед завдяки зростаючому попиту в Китаї. Інновації в нових хімічних речовинах, таких як катоди з високим вмістом марганцю або навіть іонів натрію, можуть ще більше знизити тиск на видобуток корисних копалин. Переробка відходів також може зменшити попит на мінерали. Хоча вплив у період до 2030 року, ймовірно, буде невеликим, після 2030 року внесок переробки у стримування попиту на корисні копалини буде критично важливим. За сценарієм NZE попит зростатиме ще швидше, що вимагатиме додаткових заходів з боку попиту та технологічних інновацій. Додатковий тиск чинить сьогоднішня корпоративна та споживча перевага великих моделей автомобілів, таких як спортивні позашляховики (SUV), які становлять половину всіх електричних моделей, доступних у світі, і потребують більших акумуляторів для подолання тих самих відстаней.

наліз економічної динаміки розвитку ринку електромобілів

Електромобілі набули такої популярності у світі через низку переваг над автомобілями на базі ДВЗ. Як основні плюси електромобілів можна виокремити такі:

- а) менш вартісна заправка та можливість заряджатися від простої розетки (у середньому електромобілі споживають 12 кВт на 100 км);
- б) менш вартісний ремонт, внаслідок простоти конструкції (адже в електромобілі відсутні ДВЗ та різноманітні насоси);
- в) екологічність внаслідок відсутності шкідливих викидів CO₂;
- г) відсутність шуму, що продукується роботою авто на базі ДВЗ [3].

Проте, електромобілі мають й низку недоліків:

- а) більш висока ціна, у порівнянні з автомобілем того ж класу, але на базі ДВЗ;
- б) лімітована дистанція пробігу на одному заряді;
- в) розвинена на середньому рівні інфраструктура (станції підзарядок), через що підзарядка може займати досить багато часу;
- г) ціна акумулятора складає приблизно половину вартості електромобіля[3].

Небагато сфер у світі чистої енергетики є такими ж динамічними, як ринок електромобілів. У 2021 році продажі електромобілів (EV) подвоїлися порівняно з попереднім роком, досягнувши нового рекорду - 6,6 мільйона. У 2012 році у світі було продано лише 120 000 електромобілів. У 2021 році щотижня продається вдвічі більше. Майже 10% світових продажів автомобілів у 2021 році були електричними, що в чотири рази перевищує частку ринку у 2019 році. Це призвело до того, що загальна кількість електромобілів на дорогах світу склала близько 16,5 мільйонів, що втричі більше, ніж у 2018 році. Світові продажі електромобілів продовжують стрімко зростати у 2022 році: у першому кварталі було продано 2 мільйони, що на 75% більше, ніж за аналогічний період 2021 року (рис. 1.1). Посилання [2] - [3].




Рисунок 1.1 – Частка (у %) електромобілів у загальному обсязі продажів пасажирських транспортних засобів по країнам

Джерело: [1]

Збільшення продажів електромобілів у 2021 році в першу чергу очолила Китайська Народна Республіка, на яку припала половина зростання. У 2021 році в Китаї було продано більше автомобілів (3,3 мільйона), ніж у всьому світі в 2020 році. Продажі в Європі продовжили впевнене зростання (на 65% до 2,3 млн) після буму 2020 року, а в США вони також збільшилися (до 630 000) після двох років спаду. Перший квартал 2022 року продемонстрував схожі тенденції: продажі в Китаї зросли більш ніж удвічі порівняно з першим кварталом 2021 року (на нього припадає більша частина світового зростання), у США - на 60%, а в Європі - на 25%.

Проаналізувавши світовий ринок електромобілів з позицій компаній [2], що виробляють електромобілі, визначено, що преміальні бренди займають найбільшу питому вагу на світовому ринку EV, однак найвищі ланки продажів мають масові моделі. Обсяги продажів п'ятірки світових лідерів з продажу електромобілів автовиробників за регіонами у 2021 році наведено у табл. 1.1.

За наведеною у табл. 1.1 інформацією Tesla визначається найвищою кількістю нових зареєстрованих електрокарів у світі, що майже дорівнює 936 тис. одиниць. Окрім того, варто відзначити, що весь модельний ряд бренду складається з електрокарів, а компанія успішно будує заводи в Китаї та має

амбіції щодо розвитку виробництва в Німеччині для задоволення європейського попиту. Власне, і сама Німеччина представлена брендом VW Group, що займає друге місце за кількістю проданих електромобілів - 763 тис.

Таблиця 1.1 – Обсяги продажів (тис. шт.) п'ятірки світових лідерів з продажу електромобілів автовиробників за регіонами у 2021 році

Companies of electric cars	World	Europe	China	USA	Other
Tesla	936	170	321	352	93
VW Group	763	549	154	44	15
BYD	598	1	595	0	2
GM	517	0	486	25	6
Stellantis	385	324	14	42	5

Джерело: [1]

Також грає ключову роль Китай, представлений китайським брендом BYD, що розташовується на третьому місці з 598 тис. проданих електрокарів. Загалом, найвищий рівень електричної мобільності спостерігається в Китаї.

Американський бренд GM і транснаціональна компанія Stellantis розташовуються на четвертому (517 тис. електромобілів) і п'ятому місці (385 тис. електромобілів) відповідно, вказуючи на активний внесок.

На противагу цьому, продажі електромобілів продовжують відставати в країнах із перехідною економікою. Декілька доступних моделей залишаються недосяжними для споживачів на масовому ринку. У країнах, таких як Бразилія, Індія та Індонезія, частка електромобілів у продажах автомобілів складає менше 0,5%. Проте у 2021 році спостерігалось подвоєння обсягів продажів електромобілів у деяких регіонах, включаючи Індію. Це може вказувати на можливість більшого поширення електромобілів до 2030 року, якщо буде наявна необхідна інфраструктура, інвестиції та сприятлива політика підтримки.

У 2018 році найпопулярнішою серед моделей електромобілів стала Tesla Model 3, яка зареєструвала 145 тис. одиниць. Проте, за всю історію присутності на ринку найбільш успішною моделлю є Nissan Leaf, кількість яких на дорогах сягає 363,9 тис. автомобілів. На другому місці за популярністю знаходиться Tesla Model S, продажі якої становлять 243,2 тис. одиниць.

Наразі лідером на ринку гібридних автомобілів є компанія Toyota, яка утримує 43% світового ринку. Дивно, але на сьогодні у неї немає власного масового електромобіля. Однак компанія визначила стратегічний курс і планує припинити випуск чисто бензинових і дизельних двигунів до 2040 року. Згідно з цим планом, двигуни внутрішнього згоряння залишаться лише на гібридах, які, за оцінками компанії, будуть складати приблизно 10% від усього ринку.

Щодо інших ключових гравців на ринку, відомо, що компанія Volkswagen, яка включає в себе бренди Audi і Porsche, планує до 2025 року реалізувати щорічно мільйон електромобілів, як заявив голова компанії Герберт Дісс. Додатково, Daimler, BMW, Mitsubishi, Ford, та Renault також намагаються наздогнати втрати та готуються до електромобільного буму на ринку, представляючи власні моделі та розширюючи свою присутність у цьому сегменті. На рис. 1.2 представлено динаміку щотижневих фінансових показників акцій на рівні індексів вибраних компаній, пов'язаних з транспортом, за період грудень 2018 - квітень 2022 рр. Показником, що вимірюється є арифметична прибутковість (\$) [1], яка дорівнює сумі квартальних прибутків від даної акції (приріст капіталу та дивіденди). На рис. 1.2 представлена динаміка таких індексів:

Battery – індекс 7 компаній-виробників акумуляторів;

EV - складається з 14 компаній, що спеціалізуються на електромобілях;

MSCI ACWI (All Country World Index) - глобальний індекс акцій компаній з високою та середньою капіталізацією на 23 розвитих ринках та 26 ринках, що розвиваються, у 11 секторах (для порівняння);

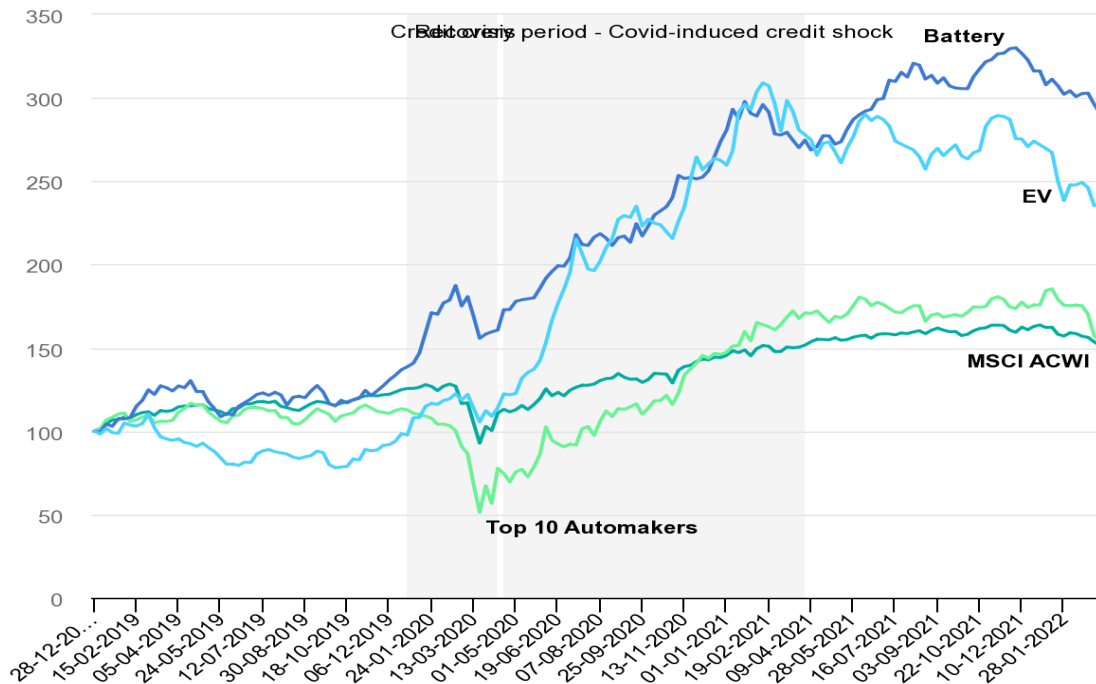


Рисунок 1.2 – Динаміка щотижневої арифметичної прибутковості акцій на рівні індексів вибраних компаній, пов'язаних з транспортом, за період грудень 2018 - квітень 2022 рр.

Джерело: [1]

Top 10 Automakers – індекс десяти найбільших автовиробників з більш широким показником публічних ринків акцій, включених до індексу MSCI ACWI.

Очевидним є значне зростання індексів компаній, що спеціалізуються на електромобілях та виробників акумуляторів з початку 2020 року, яке до того ж значно перевищує динаміку зростання глобального індексу MSCI, який характеризує стан світового ринку у цілому (в результаті всебічного спостереження за світовим ринком акцій).

Окрім того, глобальний прогноз розвитку електромобілів вказує на стійку тенденцію зростання попиту протягом наступних 20 років. Основні чинники цього росту будуть пов'язані з поширенням електромобілів у великих країнах, таких як Китай, США, Канада, а також в Європейському Союзі.

Прикладами країн, які успішно сприяють зростанню продажів електромобілів за допомогою податкових пільг, є Норвегія та Ісландія. В цих країнах відзначається найвища у світі частка електромобілів в автопарку, що свідчить про ефективність таких заходів.

На сьогоднішній день, щодо виробників електромобілів, Китай зберігає лідерство в цьому сегменті, а компанія Tesla визначається як провідний гравець на світовому ринку електромобілів, з найпопулярнішою моделлю Tesla Model 3.

бґрунтування значення ефективного розвитку ринку електромобілів та його прогнозування

Для того щоб виявити перспективи розвитку та використання електромобілів, розглянемо вплив використання електромобілів на такі сфери життя та діяльності людини: навколишнє середовище, політика, економіка, суспільство, інфраструктура і техніка [1].

Навколишнє середовище:

- зменшення викидів: електромобілі сприяють зменшенню викидів шкідливих речовин і, таким чином, сприяють поліпшенню якості повітря та зменшенню забруднення навколишнього середовища;
- використання відновлюваних джерел енергії: для максимізації позитивного впливу на навколишнє середовище важливо сприяти використанню відновлюваних джерел енергії для заряджання електромобілів.

Політика:

- стимулювання виробництва та покупки: податкові пільги, субсидії та інші заходи можуть стимулювати виробництво та покупку електромобілів;
- заборона виробництва традиційних автомобілів: країни можуть встановлювати обмеження на виробництво та продаж автомобілів з ДВЗ, щоб сприяти переходу до більш екологічно чистих технологій.

Економіка:

- ринок праці: зростання виробництва електромобілів може впливати на ринок праці, створюючи нові робочі місця у секторі виробництва та технологій;

- електроенергетика: зростання попиту на електроенергію для заряджання електромобілів може вплинути на енергетичний сектор та інфраструктуру.

Суспільство:

- прийняття споживачами: суспільство повинно бути готове приймати та використовувати електромобілі. Розуміння та прийняття нових технологій грає важливу роль.

Інфраструктура:

- зарядні станції: розвиток мережі зарядних станцій є ключовим аспектом для сприяння використанню електромобілів;

- споживчий попит: забезпечення належного рівня доступності та зручності для користувачів електромобілів.

Техніка:

- розвиток технологій батарей (засобів накопичення електроенергії): покращення технологій батарей для збільшення дальності їзди та тривалості заряду є важливим аспектом.

Стала політична підтримка є головною опорою. Державні витрати (у світі загалом?) на субсидії та стимули для електромобілів майже подвоїлися у 2021 році, досягнувши майже 30 мільярдів доларів США. Дедалі більше країн зобов'язалися поступово відмовитися від двигунів внутрішнього згоряння або мають амбітні цілі щодо електрифікації транспортних засобів на найближчі десятиліття. Тим часом багато автовиробників мають плани щодо електрифікації своїх автопарків, які виходять за рамки політичних цілей. Нарешті, у 2021 році було доступно в п'ять разів більше нових моделей електромобілів, ніж у 2015 році, що підвищило їхню привабливість для споживачів. Кількість моделей електромобілів, доступних на ринку, становить близько 450 тис. шт. [1] (рис. 1.3.).




Рисунок 1.3. Продажі та доступні моделі за регіонами, 2016-2021 рр.

Джерело: [1]

Найбільш ефективними заходами стимулювання розвитку електромобілів в різних дослідженнях вважаються пільги і знижки при покупці [4]. Оскільки висока вартість є однією з основних перешкод для широкого впровадження електромобілів, то заходи, спрямовані на зниження одноразового платежу при їх придбанні, безперечно, є ефективними.

Проте недавні дослідження ефективності різних стимулюючих заходів, проведених в країнах з успішним досвідом розвитку електромобільного транспорту, свідчать, що заходи, спрямовані на зниження вартості експлуатації або поліпшення зручності використання електромобіля, також виявляють високий рівень ефективності [6]. Тож у сучасному світі кожна країна обирає власну стратегію підтримки розвитку електромобільного

транспорту. Розглянемо конкретні приклади стимулюючих заходів, спрямованих на зниження загальної вартості (покупки та експлуатації) електромобіля, що вже вживаються в різних країнах [6].

У Китаї придбання електромобіля (ЕВ) звільнене від податку на продажі та акцизного збору. Сума податкових пільг розраховується індивідуально, враховуючи тип, об'єм двигуна і вартість автомобіля, і може коливатися від 6 000 до 10 000 доларів США. Крім того, електромобілі не оподатковуються податком на майно.

У Франції, починаючи з 2013 року, функціонує програма часткового субсидування для покупки електромобіля. Сума субсидій при придбанні електромобіля становить 6 300 євро (7 100 доларів США). Здавши утилізації дизельний транспортний засіб, покупець електромобіля може отримати додаткові бонуси у розмірі 10 000 євро (11 000 доларів США). Крім того, електромобілі, якщо вони є власністю будь-якої компанії, звільнюються від оподаткування.

У Нідерландах, починаючи з 2016 року, власники автомобілів з нульовим викидом CO₂ повністю звільнюються від сплати реєстраційного податку. Однак щодо заходів на етапі експлуатації, до них можна віднести звільнення автомобілів з нульовим викидом від сплати транспортних податків.

У Норвегії електромобілі звільнюються від податку на купівлю, середня сума якого становить приблизно 100 000 норвезьких крон (12 000 доларів США), а також не обкладаються ПДВ, який складає 25% від вартості транспортного засобу до оподаткування. З метою зменшення витрат на етапі експлуатації, власникам електромобілів в Норвегії надається звільнення від оплати за проїзд через мости, тунелі та інші платні ділянки транспортної мережі.

Зі зростанням ринку електромобілів доступ до громадських зарядних станцій також має розширюватися. Сьогодні більшість зарядних станцій для електромобілів знаходиться в житлових будинках та на робочих місцях.

Споживачі все частіше очікують від електромобілів таких самих послуг, простоти та автономності, як і від звичайних транспортних засобів.

У 2021 році [1] кількість загальнодоступних зарядних пристроїв у всьому світі наблизилася до 1,8 мільйона, третина з яких - швидкі зарядні пристрої. У цьому ж році було встановлено майже 500 000 зарядних пристроїв, що більше, ніж загальна кількість громадських зарядних пристроїв, доступних у 2017 році. У 2021 році кількість загальнодоступних зарядних пристроїв зросла на 37%, що нижче за темпи зростання у 2020 році (45%) та темпи розгортання до пандемії. Середньорічний темп зростання становив майже 50% у період з 2015 по 2019 рік. У 2021 році кількість швидких зарядок зросла трохи більше, ніж у 2020 році (48% порівняно з 43%), а повільних - значно повільніше (33% порівняно з 46%). Статистику щодо кількості точок зарядки на електромобіль і кВт на електричний LDV в розрізі різних країн світу за 2021 рік представлено у Додатку А (рис. А.2).

Отже, можна дійти висновку, що розвиток ринку електромобілів має все більший вплив на розвиток економік країн світу. Тому прогнозування динаміки продажів електромобілів стає необхідним етапом при плануванні та ефективному управлінні економікою країни.

РОЗДІЛ 2

ПРОГНОЗУВАННЯ ЧАСОВИХ РЯДІВ МЕТОДАМИ НЕЙРОМЕРЕЖЕВОВОГО МОДЕЛЮВАННЯ

наліз підходів до прогнозування часових рядів та досвіду прогнозування динаміки продажів на ринку електромобілів

Прогнозування є однією з найскладніших та важливих задач аналізу даних. Складність цього процесу визначається необхідністю аналізу та оцінки великих обсягів інформації, ускладненістю методів прогнозування та появою нових концепцій у цій галузі. Завдяки розвитку інформаційних технологій сучасний рівень розвитку методів прогнозування тісно пов'язаний з технологічними удосконаленнями. Інформаційні системи прогнозування, що враховують це, виявляються у різних наукових галузях, таких як економетрика, фінансова математика, статистика, і знаходять широке застосування в різних галузях, таких як виробництво та фінансове планування в економіці та торгівлі. Ці системи стали невід'ємною частиною управління складними системами та процесами прийняття управлінських рішень, їх використовують аналітики для оцінювання ризиків у фінансовому інвестуванні та інших сферах [12].

Прогнозування часових рядів є актуальною науковою задачею з широким спектром застосувань в теорії управління, економіці, медицині, фізиці та інших галузях. Зокрема, в контексті нейромережових методів, вони успішно використовуються для моделювання динамічних систем, які не мають заздалегідь відомої математичної моделі. Нейронну мережу можна навчити на відомих прикладах реалізацій динамічного процесу, а потім використовувати для ефективного прогнозування на нових наборах даних. Цей підхід виявляється особливо корисним у випадках, коли передбачення базується на складних динамічних взаємозв'язках, а апріорна математична модель системи невідома чи складна для визначення [13].

Особливість прогнозування часових рядів полягає в тому, що аналіз виключно обмежується даними спостережень без врахування додаткової інформації та відсутність аналізу впливу зовнішніх факторів. Незважаючи на те, що такий аналіз може виглядати обмеженим, прогнози часових рядів часто є високоточними. Розробка систем прогнозування часових рядів включає в себе використання різноманітних алгоритмів і методів, які відрізняються складністю впровадження, рівнем достовірності, обчислювальною складністю, часовими витратами та ін. Задача прогнозування значень, тренду та характеристик часового ряду виявляється надзвичайно актуальною, оскільки саме часові ряди можуть успішно застосовуватися для моделювання процесів, які були наведені вище.

Основні відмінності часових рядів від простих стохастичних вибірок включають:

- пов'язаність послідовних показників у часі в часових рядах;
- інформаційна значущість показників типового часового ряду зменшується при достатньому віддаленні цільового значення від шуканого (або спостережуваного) значення;
- збільшення кількості показників часового ряду не впливає на точність статистичних характеристик;
- при наявності закономірностей у часових рядах точність визначення статистичних характеристик зменшується [35] .

Процес побудови часових рядів базується на можливості та необхідності порівняння окремих показників. Це досягається за умови, що всі елементи ряду відображають явище, характеристики якого можна представити у вигляді дискретного набору даних на часових проміжках. При цьому кожне значення кожного показника такого явища слід фіксувати через однакові часові інтервали, і час спостереження має бути достатньо великим для виявлення стійкої тенденції окремого процесу.

Часові ряди поділяються на одномірні, отримані при фіксованій кількісній характеристиці, та багатовимірні, отримані при спостереженні

декількох характеристик виділеного об'єкта. Вони можуть бути дискретними або неперервними. У дискретних рядах можна виділити ряди для рівновіддалених моментів спостереження і для довільних моментів. Також часові ряди бувають детермінованими і випадковими: перші отримуються на основі значень невідповідної функції, а другі є результатом реалізації випадкової величини. Гетероскедастичність є ще однією характеристикою часового ряду, позначаючи, що дисперсія часового ряду є функцією від часу.

Моделі для аналізу часових рядів можуть приймати різноманітні форми і представляти собою різні стохастичні процеси.

Взагалі, (зокрема у літературі [35, 36]) широко застосовуються дві основні лінійні моделі часових рядів: моделі авторегресії (AR) та ковзного середнього (КС). Їх комбінація призводить до двох моделей - авторегресії з ковзним середнім (АРКС) і авторегресії з інтегрованим ковзним середнім (АРІКС). Модель авторегресійна фракційно-інтегрована ковзного середнього (ARFIMA) узагальнює зазначені вище моделі. Для прогнозування сезонних часових рядів використовується модифікація моделі АРІКС, а саме - сезонна авторегресія з інтегрованим ковзним середнім (САРІКС).

Модель АРІКС та її різноманітні варіанти ґрунтуються на відомому принципі Бокса-Дженкінса, і тому вони також часто відомі як моделі Бокса-Дженкінса. Лінійні моделі викликають значний інтерес через свою відносну простоту в розумінні та реалізації. Проте багато практичних часових рядів проявляють нелінійні закономірності. Наприклад, як зауважує Р. Парреллі в [35], нелінійні моделі є ефективними для прогнозування змін волатильності в економічних і фінансових часових рядах. З урахуванням цих фактів, в літературі пропонується різноманіття нелінійних моделей, включаючи відомі авторегресивні, такі як модель умовної гетероскедастичності (ARCH) [36] і її варіанти, такі як узагальнена ARCH (GARCH) [35, 36], експоненційно узагальнена ARCH (EGARCH) [38] та інші. Також серед них зустрічаються модель нелінійної авторегресії (NAR), модель нелінійного ковзного середнього (NMA) [36] та інші.

Авторегресія з ковзним середнім (АРКС) є важливою лінійною моделлю для аналізу часових рядів, що визначається комбінацією двох ключових компонентів: авторегресії (АР) і ковзного середнього (КС). Модель АРКС визначається взаємодією між попередніми значеннями часового ряду та випадковими шумами, що характеризуються ковзним середнім. Це дозволяє враховувати попередні зміни в часовому ряді та враховувати вплив ковзних середніх значень на його поведінку. Модель АРКС виявляється особливо корисною при аналізі та прогнозуванні часових рядів, оскільки вона дозволяє враховувати як локальні, так і глобальні залежності в динаміці даних. Такий підхід забезпечує здатність моделі ефективно адаптуватися до змін у вихідних даних та допомагає у виявленні тенденцій та регулярностей в часовому ряді для більш точного прогнозування.

Аналіз стаціонарності є ключовим етапом у вивченні та моделюванні часових рядів, оскільки від стаціонарності залежить правильність застосування ряду статистичних методів та моделей. Стаціонарність вказує на те, що статистичні властивості часового ряду залишаються сталими в часі, такі як середнє значення та дисперсія.

Один із методів для оцінки стаціонарності - використання статистичних тестів, таких як тест Дікі-Фуллера чи тест KPSS (Квандт-Перрі-Шаннан). Тест Дікі-Фуллера випробовує гіпотезу про наявність одиничного кореня у ряді, що вказує на нестаціонарність. У випадку відхилення від цієї гіпотези можна прийняти, що ряд є стаціонарним. Тест KPSS, навпаки, перевіряє гіпотезу про лінійний тренд у ряді та використовується для виявлення нестаціонарності.

Крім тестів, важливо візуально оцінити часовий ряд шляхом побудови графіків, таких як графік часового ряду та його автокореляційна функція (ACF). Аномалії у цих графіках можуть надати інформацію про можливу нестаціонарність або вказати на необхідність застосування додаткових методів, таких як диференціювання чи інші перетворення даних для досягнення стаціонарності.

Функція автокореляції (АКФ) відображає ступінь кореляції між значеннями часового ряду та його власними лагами (зсувами в часі). Графік АКФ дозволяє виявити періодичні закономірності, цикли та інші шаблони в ряді. За допомогою АКФ можна визначити, на які лаги впливають значення часового ряду.

Функція часткової автокореляції (ЧАКФ) відображає ступінь кореляції між значеннями часового ряду та його лагами, при урахуванні впливу проміжних лагів. Графік ЧАКФ дозволяє визначити "чистий" ефект кожного лагу, виключаючи вплив інших проміжних лагів. Це допомагає ідентифікувати значущі лаги, що може бути корисно при визначенні оптимальної моделі для прогнозування часового ряду. Аналіз АКФ та ЧАКФ сприяє виявленню та розумінню внутрішньої структури ряду, що є важливим етапом при моделюванні часових рядів.

Модель ARIMA (Autoregressive Integrated Moving Average) є широко використовуваним інструментом для аналізу та прогнозування часових рядів. Ця модель об'єднує три ключові компоненти: авторегресію (AR), інтеграцію (I) та ковзне середнє (MA):

- авторегресія (AR) – цей компонент вказує, що значення часового ряду в даний момент часу залежать від його попередніх значень. Параметр AR (p) визначає кількість лагів, які враховуються у моделі, тобто наскільки далеко в минуле ми звертаємось для врахування впливу;

- інтеграція (I) – ця частина моделі вказує на кількість диференціацій, які необхідно виконати для забезпечення стаціонарності часового ряду. Параметр I (d) визначає порядок диференціації, що впливає на те, як сильно ми "згладжуємо" або робимо ряд стаціонарним;

- ковзне середнє (MA) – цей компонент відображає вплив попередніх значень шуму часового ряду. Параметр MA (q) визначає кількість лагів шуму, які враховуються у моделі. Кожна компонента AR, I та MA додається разом для формування загальної ARIMA-моделі, яка може бути

використана для прогнозування майбутніх значень часового ряду на основі його минулих значень та структури.

тучні нейронні мережі: сутність та структурна класифікація

Сучасне зацікавлення штучним інтелектом, зокрема нейронними мережами, визначається їхньою потужністю в розв'язанні різноманітних завдань, таких як прогнозування, розпізнавання, класифікація, управління та прийняття рішень. Нейронні мережі, як правило, використовуються завдяки їхній схожості з нашим власним мозком, розширеним можливостям та перспективам ефективного застосування. Це пояснюється тим, що наш мозок, за висловлюванням вчених, використовує лише невелику частину свого потенціалу, що вкладає високий потенціал розвитку штучних нейронних мереж.

Нейронні мережі представляють собою потужний метод моделювання, що дозволяє відтворювати складні залежності в даних. Вони є нелінійними і, таким чином, ефективно працюють з проблемами розмірності, що часто виникають при моделюванні лінійних залежностей з численними змінними. Крім того, нейронні мережі взяли своє коріння з спроб відтворити здатність мозку до навчання та коригування помилок [25].

Цей підхід визначений створенням системи з аналогічною архітектурою та принципом функціонування, щоб створити штучний інтелект. Однією з основних переваг нейронних мереж є їхня здатність до навчання та адаптації, які надзвичайно подібні до процесів, що відбуваються у нашому власному мозку.

Важливо відзначити, що, незважаючи на велику швидкість обробки і відсутність втоми у штучних нейронних мереж, вони залишаються імітацією складної, але ефективною системи, яка спостерігається у природі - людському мозку. Однак в їхньому використанні для розв'язання завдань, таких як, наприклад, автономне водіння, вони надають реальні переваги в плані

точності та швидкості реакції, що робить їх важливим елементом сучасних технологій та інновацій в автомобільній промисловості [31].

Сьогодні спостерігається широке застосування нейронних мереж у різних областях, прикладом чого є технологія FaceID, впроваджена в телефонах компанії Apple. Ця технологія використовує нейронні мережі для розпізнавання обличчя та аутентифікації власників пристроїв. Її успішність свідчить про високий рівень точності та надійності, які можуть бути досягнуті за допомогою нейронних мереж у завданнях обробки та аналізу великих обсягів даних.

Нейронні мережі надають надзвичайно потужний і гнучкий інструментарій для розв'язання різноманітних завдань, обумовлених великою кількістю та складністю вхідних даних. Їхні можливості виявляються не лише в області розпізнавання обличчя, але і в інших сферах, таких як медицина, фінанси, технічне обслуговування, мистецтво та багато інших. Це демонструє перспективи та потенціал, які нейронні мережі вносять у розвиток різних галузей технологій та наукових досліджень.

Структура нейромережі складається з трьох основних типів шарів: вхідний шар, приховані шари та вихідний шар.

Шар у нейромережі — це група нейронів, які спільно працюють і виконують певну функцію в мережі. У [20] наводиться приклад-аналогія: нейромережа представляється як багатоповерховий будинок, де кожен поверх містить кімнати (нейрони). Шари з'єднані між собою, як сходи між поверхами. У кожному шарі є своя роль у процесі обробки інформації.

У нейромережі можна виділити три основні типи шарів:

- вхідний шар: аналогічний "першому поверху" будинку, вхідний шар приймає дані ззовні, такі як зображення або текст, і передає їх до наступних шарів. Цей шар не модифікує дані, а слугує лише точкою входу для них;

- приховані шари: подібні до "середніх поверхів" будинку, приховані шари здійснюють обробку вхідних даних і передачу інформації між

шарами. Вони отримали назву "прихованими" через те, що їхні результати не надходять безпосередньо на вихід мережі. Кількість прихованих шарів та кількість нейронів у них може варіюватися в залежності від складності задачі та архітектури мережі;

- вихідний шар: порівнюється з "останнім поверхом" будинку, вихідний шар формує результат, який нейромережа передбачає на основі вхідних даних. Цей результат може представляти собою класифікацію, числове значення або іншу інформацію, залежно від типу поставленої задачі.

Шари в нейромережі фактично представляють собою групи нейронів, які спільно працюють і відповідають за різні етапи обробки інформації. Ця організація дозволяє нейромережі ефективно адаптуватися до різноманітних завдань і вирішувати різноманітні завдання обробки інформації.

Нейрон – це інформаційна одиниця нейронної мережі, яка може бути представлена наступним чином рис. 2.1:




Рисунок 2.1 – Модель штучного нейрона.

Джерело: [21]

Отже, відповідно до рис. 2.1, виділяються три основні елементи штучного нейрона:

- синапс – характеризується вагою. Через нього зв'язуються нейрони. Добуток вхідного значення x_i на вагу синапсу w_i , визначає характеристику – силу зв'язку синапсів;
- суматор – тіло нейрона, яке сумує вхідні сигнали інших нейронів;
- функція активації – розраховує вихідний рівень нейрона, який подається на вхід іншим нейронам.

Всі нейрони у шарах взаємодіють через зв'язки з вагами. Ваги відіграють ключову роль у навчанні нейромережі, оскільки вони визначають ступінь впливу одного нейрона на інший. Протягом процесу навчання ваги оптимізуються з метою мінімізації помилок у прогнозуванні мережі.

Поза вагами зв'язків, у кожного нейрона також існує параметр, відомий як зміщення (bias), який регулює активацію нейрона незалежно від вхідного сигналу. Зміщення дозволяє нейромережі ефективно контролювати активність нейрона, незалежно від вхідних даних. Цей механізм допомагає нейромережі легше пристосовуватися до різних типів даних та виконувати більш гнучкі перетворення на вхідних сигналах.

Ще однією важливою складовою нейромережі є функція активації. Вона застосовується до кожного нейрона у прихованих та вихідних шарах для визначення його активності на основі суми вхідних сигналів, зважених на відповідні ваги та з урахуванням зміщення. Функція активації може бути лінійною або не лінійною, в залежності від типу завдання та архітектури мережі. Деякі з найпопулярніших функцій активації включають сигмоїду, гіперболічний тангенс, ReLU (Rectified Linear Unit) та Softmax.

Процес навчання нейромережі включає оптимізацію ваг зв'язків та зміщень, використовуючи інформацію з навчального набору даних. Зазвичай для цього використовується метод зворотного поширення помилки (backpropagation), який ґрунтується на методі градієнтного спуску. Тривалість процесу навчання може бути значною і залежить від розміру навчального набору даних, архітектури мережі та складності поставленої задачі.

Отже, структура та складові нейромережі (НМ) включають вхідний, прихований та вихідний шари, нейрони зі зваженими зв'язками та зміщеннями, а також функції активації. Ці елементи взаємодіють для того, щоб нейромережа могла адаптуватися до вхідних даних та вирішувати складні завдання.

На практиці вибір функції активації обумовлюється специфікою задачі, ефективністю комп'ютерної реалізації та алгоритмом навчання НМ. Загальноприйнятого алгоритму вибору функції активації на сьогодні не існує, при цьому відомі деякі обмеження використання певних видів цієї функції [9].

Розрізняють два основних типи навчання НМ: безпосередньої обробки навчальних даних та ітераційний. У першому випадку вагові коефіцієнти визначаються шляхом безпосередньої одноразової обробки параметрів навчальних прикладів. Другий випадок характеризується багатократним пред'явленням НМ навчальних прикладів. Вагові коефіцієнти уточнюються під час показу кожного прикладу доти, доки мережа не буде виконувати свої функції з заданою якістю [9].

Ітераційне навчання що базується на прикладах, до складу яких входять тільки вхідні дані НМ, називається навчанням “без вчителя”. Якщо ж в прикладах крім вхідних є очікувані вихідні дані, то таке навчання називається навчанням “з вчителем”. Крім того, існують менш відомі проміжні методики навчання, наприклад – “з підкріпленням”. При апріорно заданих показниках якості, основною характеристикою методики навчання є термін її проведення, який напряму залежить від кількості ітерацій [10].

Розробка моделі нейронної мережі розпочинається з обрання відповідної архітектури, яка найкраще відповідає конкретній задачі. Вибір залежить від типу даних, їх обсягу та складності проблеми, яку потрібно вирішити. Різноманітні архітектури нейромереж, такі як згорткові (CNN), рекурентні (RNN) та глибокі (DNN), дають змогу реалізувати різні можливості для вирішення різних завдань [29].

Існує декілька основних архітектур нейромереж, кожна з яких призначена для різних типів задач та застосувань.

Штучні нейронні мережі прямого поширення (Feedforward Neural Networks, FNN). Це найпростіша архітектура нейромережі, в якій інформація передається в одному напрямку, від входу до виходу через різні шари. Вони не мають циклів або зворотних зв'язків і складаються з одного або кількох прихованих шарів.

Згорткові нейронні мережі (Convolutional Neural Networks, CNN). Згорткові нейромережі розроблені спеціально для роботи з даними, що мають просторову структуру, такими як зображення. Вони використовують згорткові шари для автоматичного виявлення особливостей зображень, замість ручного інженерного проектування особливостей.

Рекурентні нейронні мережі (Recurrent Neural Networks, RNN). Рекурентні нейромережі розроблені для роботи з послідовними даними, такими як текст або часові ряди. Вони мають зворотні зв'язки, які дозволяють пам'ятати інформацію з попередніх кроків. Це дозволяє їм краще працювати з даними, де контекст важливий.

Довга короткострокова пам'ять (Long Short-Term Memory, LSTM). LSTM – це різновид рекурентної нейромережі, який вирішує проблему затухання градієнта, яка виникає при навчанні традиційних RNN. LSTM має спеціальну структуру вузлів, які дозволяють моделі “пам'ятати” або “забувати” інформацію на протязі тривалого періоду часу. Різновиди архітектур нейромереж представлені в Додатку Б (рис. Б.1).

сновні засади прогнозування методами нейромережевого моделювання

Прогнозування представляє собою необхідний етап в інтелектуальному аналізі даних, який, незважаючи на свою значущість, є вкрай важким завданням. Задачі прогнозування ускладнені низькою якістю та обсягом вхідних даних, змінами у середовищі, де відбувається процес, і впливом

суб'єктивних факторів. Результат прогнозування завжди містить певну ступінь похибки, що залежить від використаної моделі та повноти вхідних даних. При аналізі ринку важливо враховувати його нестабільність та особливості поведінки.

Під час процесу навчання нейромережі слід керуватися кількома ключовими принципами [34].

По-перше, необхідно розподілити дані на тренувальний, валідаційний та тестовий набори для ефективності моделі та уникнення перенавчання.

По-друге, доцільно використовувати методи оптимізації, такі як градієнтний спуск або адаптивні методи, для пошуку оптимальних параметрів моделі.

По-третє, під час налаштування гіперпараметрів, таких як швидкість навчання, кількість шарів або кількість нейронів, необхідно скористатися методами, такими як перехресна перевірка або пошук на сітці, для визначення найкращих значень для вашої моделі.

Також важливо управляти процесом навчання нейромережі, використовуючи інструменти, такі як візуалізація функції втрат і метрик точності. Це дозволяє стежити за ефективністю навчання та виявляти проблеми, такі як перенавчання або недонавчання. В разі потреби можна призупинити процес навчання або внести зміни до гіперпараметрів для покращення результатів.

Враховування цих аспектів роботи з нейромережами дає змогу конструювати ефективні та надійні моделі, які спрямовані на вирішення складних задач, зокрема задачі прогнозування.

Для задачі прогнозування часових рядів, які мають певну структуру існує проблема втрати взаємозв'язку між подіями (рівнями часового ряду), що відбувалися через певний період часу. Для вирішення цієї проблеми використовуються рекурентні нейронні мережі спеціального типу - нейронні мережі з довгою короткостроковою пам'яттю.

Основою перевагою рекурентних НМ є динамічність та ітераційність обробки даних, що позитивно впливає на узагальнюючі та обчислювальні можливості. Однак потенційна нестійкість та недостатня дослідженість НМ довільної архітектури зі зворотніми зв'язками є серйозними перешкодами для їх широкого застосування. Нестійкість НМ полягає в постійній зміні стану нейронів без виникнення стаціонарного стану мережі. Наслідком нестійкості може бути як колапс процесу навчання, так і не визначеність вихідної інформації в процесі навчання нейромережі [9].

Головним недоліком рекурентних нейронних мереж є те, що мережа втрачає можливість пов'язувати наявну інформацію з вхідним набором при збільшенні різниці між ними. Ця проблема називається проблемою довготривалих залежностей і вирішується модифікацією RNN нейронних мереж – LSTM [10].

Мережі з довготривалою короткостроковою пам'яттю (LSTM) - це особливий тип штучної нейронної мережі (ШНМ), здатний навчатися довготривалих залежностей. Вони були введені Хохрайтером і Шмідхубером (1997) і вдосконалені і популяризовані багатьма людьми в наступних роботах. Вони надзвичайно добре працюють над широким спектром проблем, і зараз широко використовуються [10].


LSTM розроблена для того, щоб уникнути проблеми довготривалої залежності. Запам'ятовування інформації на довгі періоди часу – це їхня поведінка за замовчуванням, а не те, чого вони намагаються навчитися [11].

Всі рекурентні нейронні мережі мають вигляд ланцюжка повторюваних модулів нейронної мережі. У стандартних RNN цей повторюваний модуль має відносно просту структуру, наприклад, один тангенціальний шар [10].

Приклад структурної відмінності рекурентних архітектур представлено на рис. 2.2 та 2.3.

Основною складністю при роботі з мережею в наборі даних є потреба вивчення всіх компонентів для вирішення конкретної задачі. Для підвищення

ефективності навчання нейронні мережі часто формуються окремо, а потім об'єднуються в єдину структуру.



Р

и

Джерело: [30]

с

у

н

о

к

2

.

2

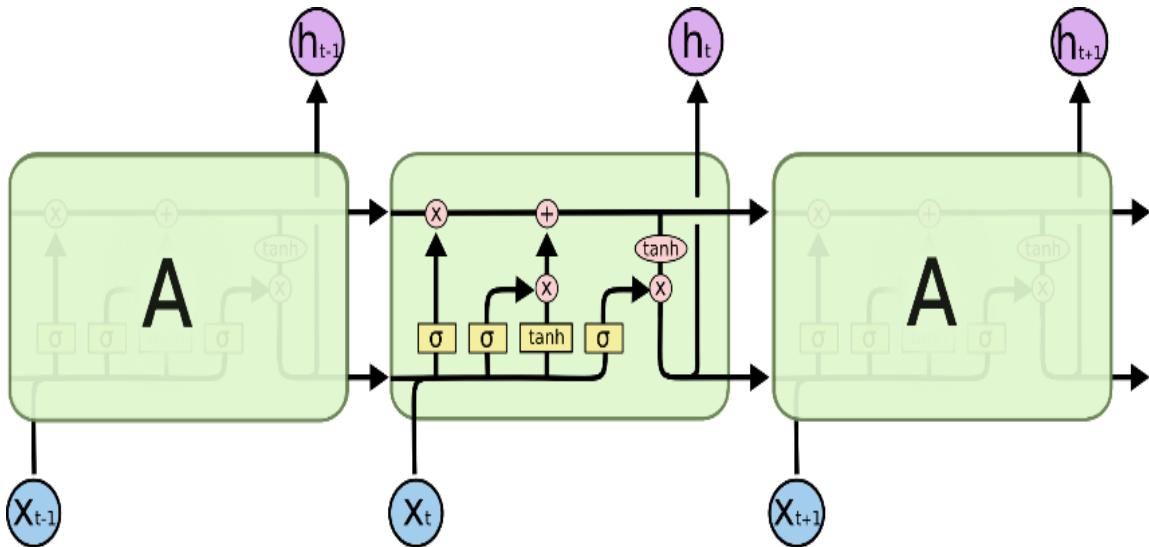


Рисунок 2.3 – Повторюваний модуль в LSTM (містить чотири взаємодіючих

Повторюваний модуль у стандартному RNN (містить один шар)

Джерело: [30]

Проте, якщо алгоритми коригування вибраних топологій належать до різних класів навчання, синхронне формування всіх модулів, що входять до набору, стає необхідним. Таким чином, важливо розробити унікальний алгоритм коригування всіх модулів для оптимального навчання в цілому.

Ансамбль - це кілька алгоритмів машинного навчання, зібраних в єдине ціле. Такий підхід часто використовується для того, щоб посилити "позитивні якості" окремо взятих алгоритмів, які самі по собі можуть працювати слабо, а ось у групі - ансамблі - давати хороший результат. При використанні ансамблевих методів алгоритми навчаються одночасно і можуть виправляти помилки один одного. Розглянемо існуючі на сьогодні види ансамблів:

- стекінг - можуть розглядатися різнорідні окремо взяті моделі. Існує мета-модель, якій на вхід подаються базові моделі, а виходом є підсумковий прогноз;

- беггінг - розглядаються однорідні моделі, які навчаються незалежно і паралельно, а потім їхні результати усереднюються. Яскравим представником цього методу є випадковий ліс;

- бустинг - розглядаються однорідні моделі, які навчаються послідовно, до того ж наступна модель має виправляти помилки попередньої.

Робота з ансамблями нейромереж науковою спільнотою виявляє низку труднощів, що вимагають детального розгляду. До ключових аспектів цих труднощів можуть бути віднесено:

- вибір оптимального типу ансамблю - оптимізація вибору конкретного типу ансамблю для вирішення конкретної задачі вимагає глибокого розуміння характеристик даних та специфіки задачі;

- тюнінг гіперпараметрів - налаштування гіперпараметрів кожного типу ансамблю та його базових моделей становить важливий етап роботи, який вимагає уваги та експертизи;

- забезпечення різноманітності базових моделей стає ключовим завданням для ефективності ансамблю, особливо при використанні схожих архітектур чи параметрів;

- обробка даних та генерація модулів для різних моделей може виявитися трудомістким завданням, оскільки для кожної моделі вимагається окремий аналіз та підготовка даних;

- обчислювальні витрати - збільшення обчислювальних витрат через використання більшої кількості моделей в ансамблі може виявитися важливим обмеженням з точки зору обчислювальних ресурсів;

- інтерпретація результатів - інтерпретація прогнозів ансамблю виникає як складне завдання через комбінацію прогнозів різних моделей, вимагаючи додаткових зусиль для розуміння процесу прийняття рішень.

Архітектура нейронної мережі несе в собі багато змінних атрибутів які призначені для оптимізації часу роботи, отриманого результату та функції навчання нейронної мережі. Структура моделі нейронної мережі для задачі прогнозування залежить від потрібного результату та поданих на вхід даних [42].

Статична модель структури нейронної мережі має статичні вектори вхідних і вихідних даних та одну розрахункову модель прогнозування. Для цієї моделі характерним є незалежність прогнозних даних а також відсутність накоплення помилок.

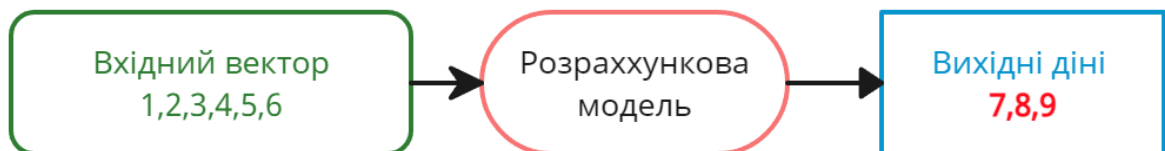


Рисунок 2.4 – Статична модель.

Джерело: [42]

Блочна модель структури нейронної мережі будується з n (кількість) моделей, кожна із яких буде прогнозувати на x значень. а при перемноженні буде будувати вихідний вектор прогнозу. Модель потребує достатньо великої кількості часу для навчання але все залежить від значення n - кількості моделей.




Рис.2.5 – Блочна модель.

Джерело: [42]

Рекурсивна модель структури нейронної мережі реалізує покроковий метод прогнозування, в основі якого лежить покрокове зміщення вхідного вектору на вихідний в залежності від горизонту прогнозування. Головний недолік полягає в накопиченні помилок з кожним наступним кроком. Існують модифікації такої моделі зі зміною вхідного вектору або кількістю розрахункових моделей.

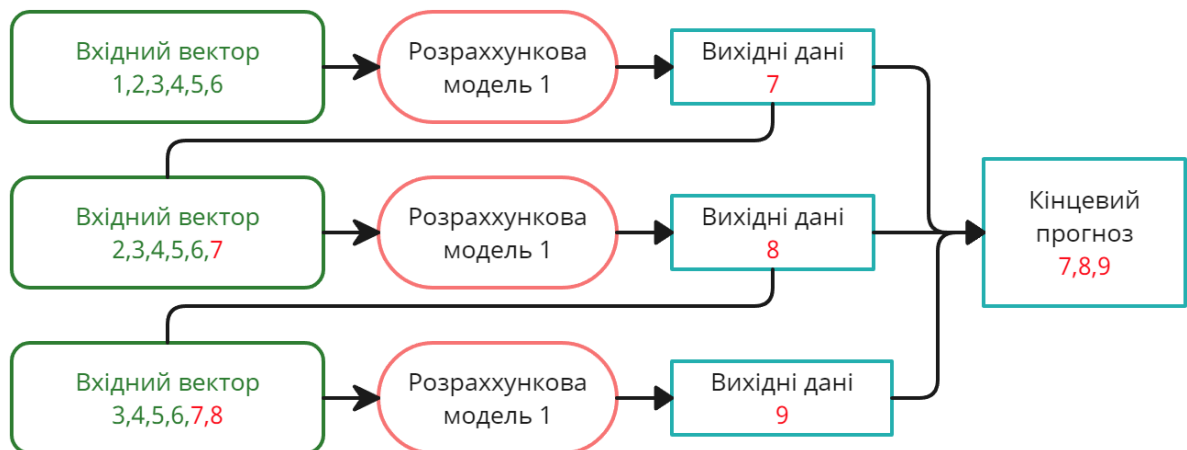


Рис.2.6 – Рекурсивна модель.

Джерело: [42]

В наш час існує велика кількість готових програмних рішень, які надають можливість реалізувати моделі для прогнозування часових рядів.

Розглянемо компоненти розробки, які зазвичай входять до складу програмних продуктів для побудови математичних моделей.

Використання мови програмування Python [37] для реалізації програм обумовлено великою кількістю доступних моделей і бібліотек. Python надає користувачам доступ до різноманітних моделей та бібліотек, включаючи як нейронні мережі, так і звичайні математичні моделі.

Використання таких бібліотек розширює можливості для отримання різноманітних метрик та результатів моделювання. Ці бібліотеки оптимізовані для виконання моделювання та представлення результатів користувачеві. Деякі бібліотеки використовуються для графічного відображення моделей, а інші для обробки масивів даних та обчислень.

Scikit-learn є потужною та популярною бібліотекою для машинного навчання в середовищі Python. Завдяки своєму простому та інтуїтивно зрозумілому інтерфейсу, вона стала вибором для багатьох дослідників та професіоналів у сфері аналізу даних. Бібліотека містить реалізації різних алгоритмів машинного навчання, таких як класифікація, регресія та кластеризація, що робить її універсальним інструментом для різних задач.

Однією з сильних сторін Scikit-learn є вбудована підтримка для крос-валідації, що дозволяє вдосконалено оцінювати ефективність моделей. Крім того, бібліотека забезпечує інструменти для візуалізації результатів, що полегшує розуміння даних та взаємодію з моделями.

Scikit-learn також допомагає в оптимізації параметрів моделей за допомогою методів, таких як пошук по сітці, що дозволяє знаходити оптимальні значення параметрів для покращення результатів. Ця бібліотека легко інтегрується з іншими популярними бібліотеками, що робить її важливим інструментом для розробників та дослідників, які працюють у сфері машинного навчання та аналізу даних. У нашому випадку, бібліотеку Scikit-learn використовують для побудови та оцінки метрик, таких як MSE та RMSE [17].

NumPy (Numerical Python) є важливою бібліотекою для мови програмування Python, спеціально розробленою для роботи з числовими даними. Основною структурою даних у NumPy є масив, який дозволяє

представляти дані у вигляді одновимірних, двовимірних та більш високорозмірних об'єктів. Це робить NumPy надзвичайно корисним для наукових обчислень, інженерії та інших областей, де операції з великими обсягами даних мають ключове значення.

Однією з сильних сторін NumPy є наявність універсальних функцій, що спрощують виконання різноманітних математичних операцій над масивами без потреби використання циклів. Це сприяє високій швидкодії та ефективності обчислень. Можливості індексації та зрізів у NumPy роблять простіше вибір та обробку підмасивів даних. Бібліотека також підтримує трансляцію, дозволяючи виконувати операції над масивами різного розміру, автоматично пристосовуючи їх до спільного формату. Загалом, NumPy є невід'ємною частиною екосистеми Python для обробки числових даних та виконання наукових обчислень [18].

Pandas і NumPy є взаємодоповнюючими бібліотеками для обробки та аналізу даних в мові програмування Python. Pandas будується на основі NumPy і використовує його масиви для зберігання та маніпуляції даними. Наприклад, об'єкти Pandas, такі як Series та DataFrame, засновані на NumPy-подібних структурах, що дозволяє ефективно працювати з великими об'ємами інформації. Pandas - це бібліотека для Python, яка надає зручні структури даних для аналізу та обробки даних. Основні об'єкти - це Series і DataFrame. Вона дозволяє читати/записувати дані, виконувати операції об'єднання, групування та агрегації. Pandas легко працює з різними форматами даних і надає зручний інтерфейс для операцій з ними. Ця бібліотека є важливою для аналізу даних та машинного навчання в середовищі Python [19].

TensorFlow і Keras є двома ключовими бібліотеками для розвитку моделей глибокого навчання в мові програмування Python. Keras (Keras) є високорівневим API для побудови та навчання нейронних мереж, тоді як TensorFlow надає базову інфраструктуру для глибокого навчання.

TensorFlow є бібліотекою з відкритим вихідним кодом, розробленою командою Google Brain. Вона надає низькорівневі інструменти для роботи з

тензорами та виконання операцій глибокого навчання, таких як створення та навчання нейронних мереж. TensorFlow забезпечує гнучкість та широкі можливості для розробки моделей глибокого навчання, включаючи підтримку різних оптимізаторів, шарів та функцій активації.

Keras, з іншого боку, раніше був окремою бібліотекою для глибокого навчання, але починаючи з версії TensorFlow 2.0, Keras став стандартним високорівневим API для побудови та тренування моделей в TensorFlow. Keras спрощує процес розробки моделей, надаючи чіткий та інтуїтивно зрозумілий інтерфейс. Заснований на концепції "збудуй та навчай", Keras дозволяє легко створювати складні нейронні мережі з декількома шарами. Отже, в сучасних версіях TensorFlow, Keras є інтегрованим компонентом бібліотеки, що надає зручний та ефективний спосіб розробки та навчання моделей глибокого навчання [15, 16].

Отже, ми розглянули основні засади, моделі та засоби прогнозування методами нейромережевого моделювання, які будемо застосовувати для прогнозування динаміки продажів на ринку електромобілів.

РОЗДІЛ 3

ЗАСТОСУВАННЯ НЕЙРОМЕРЕЖЕВОГО МОДЕЛЮВАННЯ ДЛЯ ПРОГНОЗУВАННЯ ДИНАМІКИ НА РИНКУ ЕЛЕКТРОМОБІЛІВ

бґрунтування складу та структури вхідних даних для прогнозування динаміки продажів на ринку електромобілів

Сучасний ринок електромобілів являє собою динамічну сферу, де точне прогнозування продажів стає критично важливим для ефективного управління підприємствами автомобільної індустрії. Це дослідження спрямоване на використання нейромережевого моделювання для прогнозування динаміки на ринку електромобілів 22 країн з метою удосконалення інструментарію прогнозування динаміки продажів шляхом застосування засобів нейромережного моделювання з врахуванням особливостей архітектури штучних нейронних мереж.

Вхідними даними для прогнозування є часові ряди по продажам електромобілів на ринках 22 країн за 7 років з місячним інтервалом за період з 2016 по 2022 рр. [9]. Графічне представлення часових рядів окремих країн наведено у Додатках В та Г.

Ці ряди можна охарактеризувати як неоднорідні, гетерогенні та варіативні часові ряди які представляють собою складний об'єкт дослідження, оскільки вони виявляють різноманітні та змінні характеристики протягом часу.

Задані ряди мають низку особливостей, які варіюються та є суттєвими для їх аналізу. До таких особливостей можна віднести:

- різноманітність трендів: однією з ключових особливостей є наявність різних трендів у різних періодах. Це може включати періодичні, циклічні чи інші непередбачувані зміни, що роблять аналіз складним та вимагають розширених методів моделювання;

- нестабільність дисперсії: варіативність у розподілі значень ряду змінюється в часі, що вказує на те, що ступінь невизначеності та мінливості може демонструвати коливання, що вимагає уваги до роботи з різними ступенями дисперсії;
- виявлення аномалій: наявність аномалій або виняткових подій є неоднорідною характеристикою, що вносить додаткову невизначеність у динаміку ряду та робить важким завдання прогнозування;
- зміна параметрів моделі: зазначається, що моделі, які ефективно описують ряд у певний період, можуть втрачати свою адаптивність через зміну параметрів або властивостей ряду;
- різноманіття джерел впливу: часові ряди можуть бути піддані впливу різноманітних факторів, що можуть змінюватися в часі. У контексті економічних часових рядів, це може включати різні економічні події, які вимагають подальшого дослідження їх впливу та прогнозування;

Ці аспекти підкреслюють складність аналізу та моделювання неоднорідних часових рядів у науковому дослідженні, вимагаючи використання продуманих та прогресивних методів для врахування різноманітних динамічних характеристик. Приклади графіків динаміки деяких з цих рядів представлено на рисунках 3.1 – 3.4.



Рисунок 3.1 – Продажі протягом 2016-2022 років, країни Австралія



Рисунок 3.2 – Продажі протягом 2016-2022 років, країни Великобританія

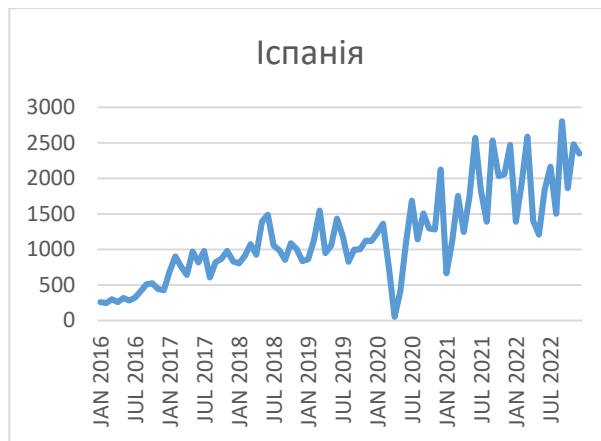


Рисунок 3.3 – Продажі протягом 2016-2022 років, країни Іспанія



Рисунок 3.4 – Продажі протягом 2016-2022 років, країни Австралія

Для візуалізації даних будемо використовувати бібліотеку Matplotlib в середовищі програмування Python. Ця бібліотека характеризується простотою та легкістю у використанні синтаксису, завдяки чому вона є важливим інструментом для науковців, інженерів та дослідників даних для створення різноманітних графіків і діаграм. Matplotlib підтримує різні види графіків, такі як лінійні графіки, стовпчаті діаграми, кругові діаграми та scatter plots. Одна з сильних сторін Matplotlib - це можливість налаштувати вигляд графіків, щоб вони відображали дані так, як вам потрібно. Ви можете змінювати кольори, шрифти, розміри та інші параметри для досягнення оптимального візуального ефекту. Matplotlib також підтримує створення анімацій та вбудовані інструменти для збереження графіків у різних форматах. Загалом, Matplotlib становить важливий інструмент для відображення та розуміння даних у вигляді графічних представлень[14].

Вибір правильних даних для навчання нейромережі є важливим етапом, і деякі типові проблеми можуть впливати на ефективність моделі. Недостатній обсяг даних може призвести до перенавчання, а велика нерівномірність класів може призвести до викривленого навчання на популярних класах. Для розв'язання проблеми з недостатньою кількістю даних, рекомендується використовувати аугментацію даних, збільшувати обсяг вибірки, або використовувати попередньо навчені моделі для передавання знань. У випадку

нерівномірності класів корисно використовувати стратегії балансування, такі як випадковий вибір або зважені функції втрат. Також важливо, щоб ваша вибірка була репрезентативною для реального використання моделі, уникайте вибірок, які не відображають різноманіття даних, що може виникнути у реальних умовах використання.

Для запобігання більшості незручностей при тренуванні та навчанні було знайдено рішення, а саме ітераційно поступове нагромадження – парсинг даних (автоматизований збір та структурування даних з Інтернету). Для цього скористаємося бібліотекою `yfinance` яка дає змогу надавати в потрібному форматі потрібні дані по тикерам (коротким назвам інструментів в біржовій інформації).

`yfinance` [9] – це Python-бібліотека, яка надає простий та зручний інтерфейс для отримання фінансових даних з Yahoo Finance. Одна з ключових можливостей цієї бібліотеки - це отримання історичних даних цін на акції, обсягів торгів та інших фінансових показників. Завдяки `yfinance`, користувачі можуть легко отримувати дані для подальшого аналізу та використання у фінансових дослідженнях. Бібліотека також дозволяє отримувати інформацію про торгові сесії, включаючи високий, низький, відкритий та закритий курси акцій для кожного торгового дня. Крім того, вона надає можливість отримання поточних даних цін та інших фінансових параметрів для акцій та інших фінансових інструментів у реальному часі. Для аналізу інвестиційних портфелів чи проведення фінансових досліджень, `yfinance` стає зручним інструментом, дозволяючи швидко та ефективно отримувати різноманітні фінансові дані з одного з найпопулярніших фінансових ресурсів в Інтернеті.

Реалізація інструменту для парсингу та створення дата сету представлено в Додатку Д (рис.Д.1 та рис. Д.2).

Також потрібно зазначити, що на рівні роботи з даними є важливий аспект, який має назву скалювання. У нейромережевому програмуванні скалювання відіграє важливу роль у стандартизації та нормалізації вхідних даних чи активацій, що дозволяє забезпечити стабільність та ефективність

навчання моделі. Два основних методи скалювання — min-max scaling та z-score scaling, і кожен із них має свої особливості та використання.

Min-Max Scaling – метод, який забезпечує приведення вхідних даних до визначеного діапазону, зазвичай між 0 та 1. Процес скалювання здійснюється шляхом відняття мінімального значення та подальшого ділення на різницю максимального та мінімального значення. Мінімакс-скалювання особливо корисне в ситуаціях, де важливим є збереження відношення між значеннями.

Z-Score Scaling – метод, відомий як стандартизація, приводить дані до розподілу з середнім значенням 0 та стандартним відхиленням 1. Використовуючи z-score, вхідні дані виражаються у відстанях від середнього значення у одиницях стандартного відхилення. Стандартизація особливо ефективна в умовах, коли розподіл даних не є рівномірним чи відомим.

Скалювання важливе для стабільності градієнтів та прискорення процесу навчання, особливо в глибоких нейронних мережах. Використання цих методів сприяє покращенню швидкості збіжності моделі, зменшенню ризику виникнення проблем з перенавчанням чи невдачею градієнтів, і в кінцевому результаті сприяє вдосконаленню якості та узагальнюючої здатності нейромережі.

озробка архітектури штучної нейронної мережі для задачі прогнозування динаміки продажів на ринку електромобілів

Базовим складовим елементом штучної нейронної мережі є штучний нейрон. Декілька штучних нейронів взаємодіють між собою та утворюють нейронну мережу. Ця мережа ефективно обробляє інформацію та вдало адаптується до змін у зовнішньому середовищі. Процес роботи штучної нейронної мережі полягає у перетворенні вхідного вектору значень (сигналів) на вихідний. Характеристики нейронів, структура, архітектура та методи тренування визначають цей процес. Основними характеристиками є:

- парадигма нейронної мережі: це визначає спосіб використання та навчання нейронної мережі;
- структура штучної нейромережі: Це вказує, як нейрони пов'язані та взаємодіють між собою;
- архітектура штучної нейромережі: це визначає тип або типи нейронів у мережі та їх взаємодію. важливо враховувати, що різні парадигми можуть бути реалізовані на основі однієї архітектури і навпаки.

Розглянемо детальніше архітектури прогнозування часових рядів, обійшовши деякі менш складні варіанти:

- статистичні методи ARIMA - це модель, що об'єднує авторегресію (AR), інтегрування (I) та ковзне середнє (MA) для аналізу та прогнозування часових рядів. Цей метод особливо ефективний для стаціонарних часових рядів;
- методи машинного навчання - Random Forests, Gradient Boosting Machines. Використовуються для створення ансамблів дерев рішень та можуть враховувати різноманітні признаки, такі як сезонність, погодні умови тощо. Градієнтні бустинги, наприклад, можуть враховувати слабкі моделі та підсилювати їх для отримання точніших результатів;
- традиційні рекурентні нейронні - Simple RNN: RNN здатні моделювати залежності в часових рядах, але вони можуть мати проблему з вивченням довгострокових залежностей через проблему зниклих градієнтів.

Удосконалені Рекурентні Нейронні Мережі:

- LSTM (Long Short-Term Memory): LSTM вирішує проблему зниклих градієнтів за допомогою введення воріт, які дозволяють зберігати та видаляти інформацію з пам'яті моделі на різних часових шарах(рис. 3.5);
- GRU (Gated Recurrent Unit): GRU, подібно до LSTM, також використовує механізм воріт для ефективного моделювання довгострокових залежностей, але він менш складний та може бути швидше навчений(рис. 3.5);
- Temporal Convolutional Network - це архітектура, яка використовує сверточні шари для моделювання часових рядів. Вона дозволяє отримувати

інформацію з різних часових вікон, спрощуючи управління довгостроковими залежностями. TCN може бути ефективним у великих послідовностях та задачах прогнозування.




Рисунок 3.5 – Схеми Удосконалених Рекурентних Нейронних Мереж:

а) LSTM; б) GRU

Джерело: [30]

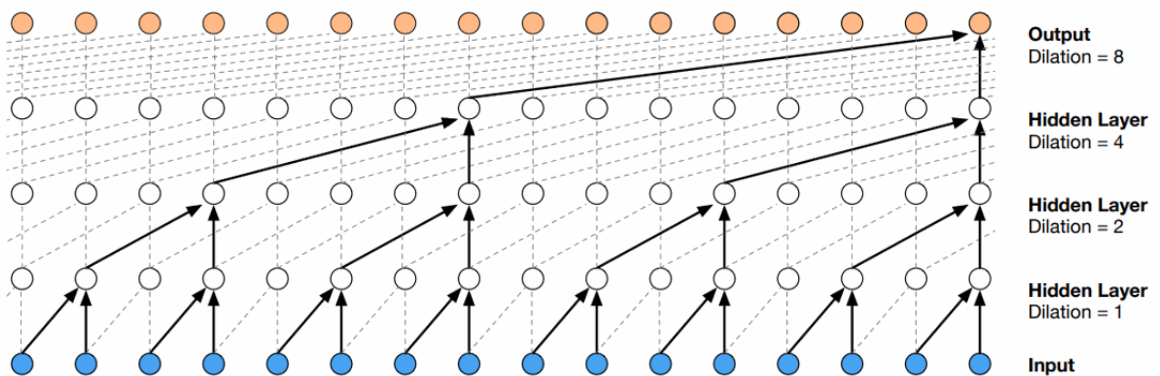


Рисунок 3.6 – Схема Удосконаленої Рекурентної Нейронної Мережі

Temporal Convolutional Network

Джерело: [21]

Для розуміння потрібно розглянути працюючу на даний момент програму, яка має подібний функціонал. Наприклад, пакет STATISTICA пропонує тільки дві архітектури для прогнозування, а саме багаточаровий

персептрон і мережу з радіальними базисними функціями (RBF). Розглянемо їх у контексті машинного навчання:

- багат шаровий персептрон (MLP) є формою штучної нейромережі, яка складається з кількох шарів нейронів, включаючи вхідний шар, внутрішні (приховані) шари та вихідний шар. Кожен нейрон у шарі пов'язаний з кожним нейроном наступного шару. MLP використовує функції активації для передачі інформації через мережу та навчається з використанням алгоритму зворотного поширення (рис. 3.6);




Рисунок 3.6 – Архітектура багат шарового персептрона (MLP)

Джерело: [10]

- використання: MLP може бути ефективним для прогнозування, класифікації та апроксимації складних функцій, але його ефективність може залежати від адекватного вибору гіперпараметрів, таких як кількість шарів, нейронів у кожному шарі та функції активації;

- мережа з радіальними базисними функціями (RBF) - це мережа, в якій вхідні дані обробляються через радіальні базисні функції. Кожна функція відповідає центру (радіусу) та зважує вхідні дані залежно від відстані між вхідними даними та центром функції. Використання: Мережі з RBF можуть бути ефективними у випадках, коли вхідні дані можна ефективно представити як суперпозицію радіальних базисних функцій. Вони часто використовуються

для апроксимації нелінійних функцій та прогнозування часових рядів (рис. 3.7).

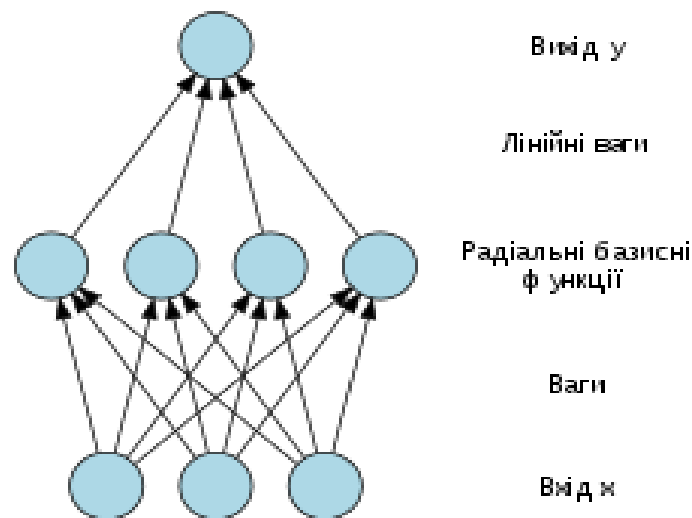


Рисунок 3.7 – Архітектура мережі з радіальними базисними функціями (RBF)

Джерело: [21]

Обмежена кількість архітектур може впливати на гнучкість та вибір моделей у випадках, коли потрібно вирішити складні завдання машинного навчання. У більш «просунутих» сценаріях ми могли би розглянути використання більш складних архітектур, таких як LSTM або TCN, які дозволяють більш ефективно моделювати довгострокові та складні залежності в даних.

В більш «просунутих» сценаріях, де потрібно ефективно моделювати довгострокові та складні залежності в даних, може виникнути необхідність у більш розширених архітектурах, таких як рекурентні нейронні мережі (зокрема, LSTM) або трансформери, які використовують механізм визначення уваги.

Зазвичай ці архітектури можуть легко адаптуватися до різноманітних завдань прогнозування та враховувати більше властивостей даних. Наприклад, LSTM може ефективно враховувати довгострокові залежності, а

трансформери можуть легко працювати з послідовностями різної довжини, роблячи їх більш адаптивними до різноманітних даних.

Кластеризація - це техніка аналізу даних, що полягає у групуванні схожих об'єктів в один клас або "кластер". Відмінність між об'єктами всередині кластера мінімальна, тоді як об'єкти, що належать різним кластерам, виявляють велику варіативність. У контексті часових рядів, кластеризація набуває особливого значення, оскільки дозволяє виявляти подібні зміни та структури в часових вибірках.

Завдання кластеризації відноситься до статистичної обробки та належить до широкого класу завдань навчання без вчителя. Основна відмінність між кластеризацією та класифікацією полягає в тому, що перелік кластерів не є наперед визначеним і формується в процесі роботи алгоритму. Загальний підхід до застосування кластерного аналізу можна узагальнити в наступні етапи:

- Етап 1. Ідентифікація вибірки об'єктів для кластеризації;
- Етап 2. Визначення множини змінних, за якими планується проводити оцінку об'єктів у вибірці. При необхідності нормалізація значень змінних;
- Етап 3. Обчислення значень тієї або іншої міри схожості між об'єктами;
- Етап 4. Застосування одного з методів кластерного аналізу для створення груп подібних об'єктів (кластерів);
- Етап 5. Перевірка вірогідності результатів кластерного розв'язку.

Враховуючи вказані вище обставини, було вирішено впроваджувати індивідуальну архітектуру ансамблевого типу для розв'язання зазначеної проблеми. Структуру роботи моделі в цілому представлено на рисунку 3.8.

Для повноцінного розкриття функціоналу моделі, розділимо роботу моделі на 3 етапи та представимо їх окремо.



Рисунок 3.8 – Схематичне представлення роботи моделі.

На *Етапі 1*, який можна охарактеризувати як підготовчий та формувальний, розробляється базова нейромережева модель для кластеризації часових рядів. Модель навчається на місячних даних щодо продажів електромобілів у 22 країнах протягом семи років. Це призводить до створення основи нейронної мережі, в якій фіксуються кластери, що відповідають конкретним країнам. Одночасно виділяється окремий кластер з метою можливого подальшого видалення «непотрібних» часових рядів у майбутньому. (рис.3.9).

На *Етапі 2* – відбувається формування бази даних для навчання прогнозової моделі за рахунок залучення подібних (за динамікою) часових рядів тікерів. Робота цього етапу ініціюється із використанням бібліотеки `ufinance` для процесу отримання тікерів фінансових даних з платформи Yahoo Finance. Цей етап може бути визначений як наповнення кластерів для подальшого аналізу. Далі кожен часовий ряд піддається процесу класифікації,

і у випадку, якщо фіксується належність часового ряду до конкретного кластеру, відповідний часовий ряд реєструється в базі даних цього кластеру.

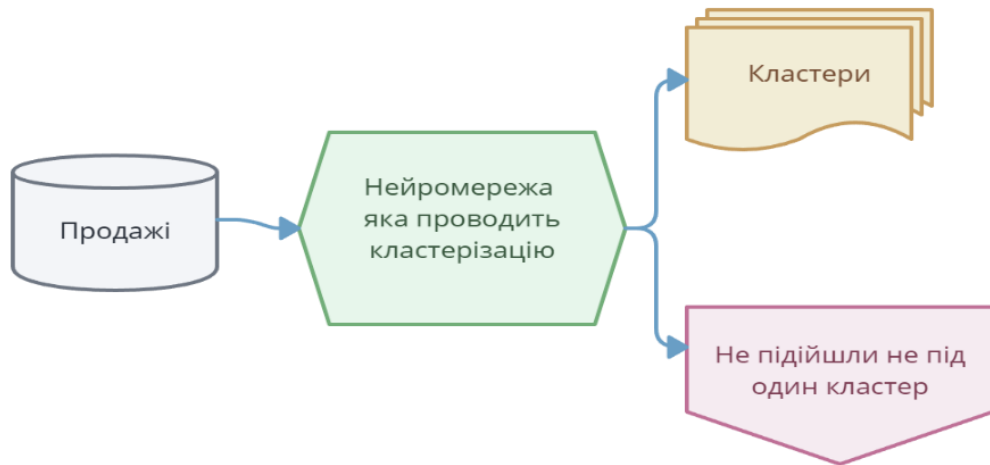


Рисунок 3.9 – Схема Етапу 1

В іншому випадку він виключається. Цей етап є циклічним і продовжується, залежно від потреби в обсязі навчальної вибірки для подальшого прогнозування. (рис.3.10).

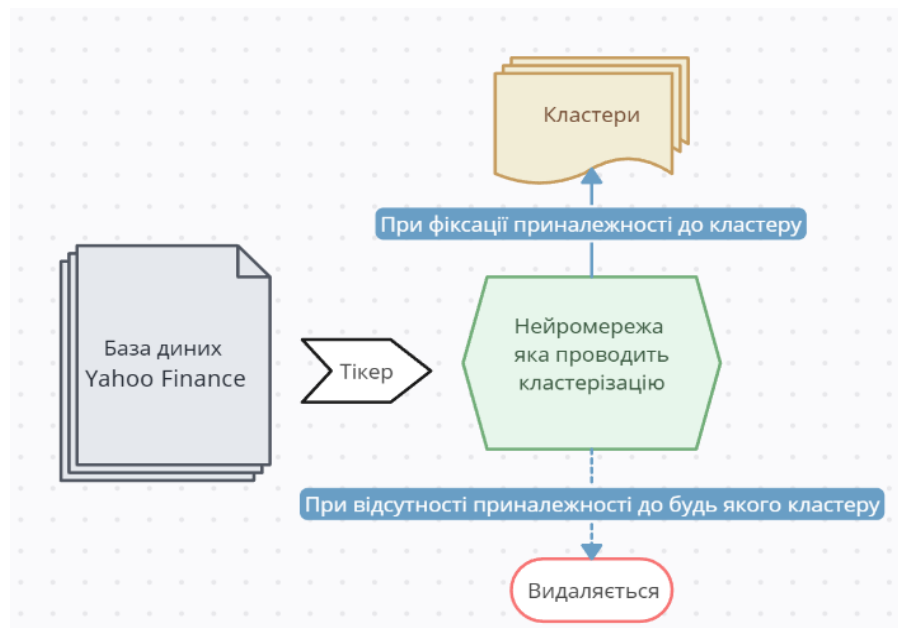


Рисунок 3.10 – Схема Етапу 2

Етап 3 полягає у створенні прогнозних моделей для кожного кластеру та їхнє навчання для подальшого використання в прогнозному аналізі. Цей етап орієнтований на використання інформації, отриманої на другому та першому етапах, оскільки якість та обсяг накопичених даних безпосередньо впливають на розробку прогнозних нейромережових моделей. Загальна схема Етапу 3 представлена на рис.3.11.

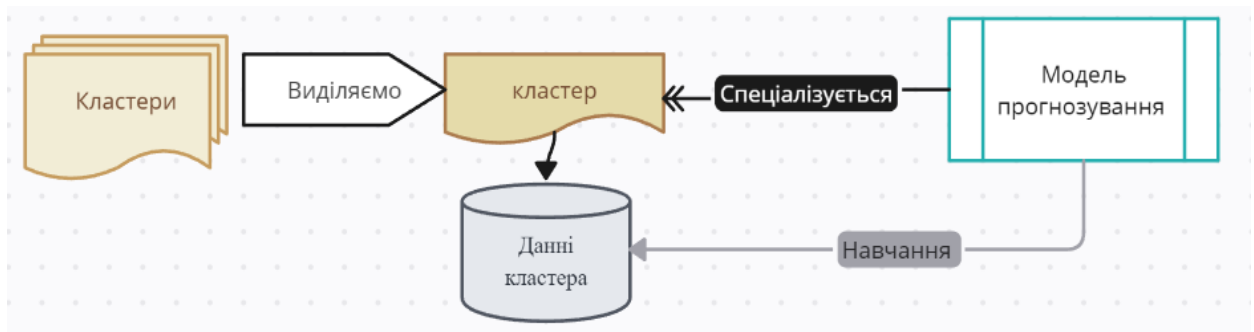


Рисунок 3.11 – Схема Етапу 3

езультат застосування нейромережевого моделювання та його аналіз

Після вивчення різних моделей прогнозування часових рядів виникає наступне суттєве питання - реалізація, або застосування цих методів для створення прогнозів. При використанні конкретної моделі на реальному або імітованому часовому ряді, вихідні дані спочатку розділяються на дві частини: тренувальний і тестовий набори. Спостереження в навчальному комплекті використовуються для побудови бажаної моделі. Часто невелика частина навчального комплекту зберігається для цілей валідації і відома як валідаційний комплект. Іноді проводиться препроцесинг, що може включати в себе нормалізацію даних, логарифмічні або інші перетворення.

Після побудови моделі вона використовується для створення прогнозів. Спостереження тестового набору аналізуються для перевірки точності передбачення цих значень, використовуючи відповідну модель. При необхідності застосовується зворотне перетворення для перетворення

прогнозованих значень у вихідну шкалу. Для оцінки точності конкретної моделі або для порівняння різних моделей розглядається їх відносна продуктивність на тестовому наборі даних.

У зв'язку з фундаментальною важливістю прогнозування часових рядів у багатьох практичних ситуаціях, вибір конкретної моделі вимагає належної обережності. З цієї причини в літературі запропоновано різні показники для оцінки ефективності прогнозу та порівняння різних моделей, вони також відомі як показники продуктивності. Кожен з цих показників є функцією фактичних і прогнозованих значень часового ряду.

Середня абсолютна помилка (MAE) є метрикою, яка визначає середню величину помилок у прогнозах, без врахування їхнього знаку. Іншими словами, ця метрика визначає середнє значення абсолютних різниць між прогнозованими значеннями та фактичними спостереженнями у тестовому наборі, не враховуючи напрямку помилки.

Властивості MAE включають:

- вимірює середнє абсолютне відхилення між прогнозованими та вихідними значеннями;
- іноді відома як Середнє абсолютне відхилення (MAD);
- показує величину загальної помилки, що виникла в результаті прогнозування;
- у MAE вплив позитивних і негативних помилок не компенсується;
- не вказує на напрямок помилок, відмінно від MFE;
- для точного прогнозу значення MAE повинно бути якнайменше;
- як і MFE, MAE залежить від масштабу вимірювань і трансформації даних;
- екстремальні помилки прогнозу не відображаються якісно в панелі MAE.

MARE, або середня абсолютна відсоткова помилка, є метрикою, призначеною для оцінки точності прогнозу. Ця метрика враховує величину помилок у відсотках порівняно зі значеннями вихідного ряду.

Використовується MAPE для порівняння різних моделей, які застосовуються до одного ряду, а також для оцінки економічного виграшу, що виникає внаслідок підвищення точності прогнозу.

Властивості MAPE включають:

- а) цей показник представляє відсоток від середньої абсолютної похибки;
- б) не залежить від масштабу виміру, але може бути вплинути трансформація даних;
- в) не вказує на напрямок похибки;
- г) не призначений для виявлення екстремальних відхилень;
- д) у випадку протилежних знакових похибок вони не компенсують одна одну.

RMSE, або квадратний корінь середньої квадратичної помилки, є метрикою, яка визначає корінь середньої величини квадратичних різниць між прогнозованими значеннями та фактичними спостереженнями у тестовому наборі.

Властивості RMSE включають:

- RMSE представляє собою квадратний корінь з обчисленого середньої квадратичної помилки (MSE);
- Всі властивості MSE залишаються в силі і для RMSE;
- Часові ряди, як послідовність спостережень, мають свої особливості, особливо при роботі з великим обсягом даних. До цих особливостей відносяться наступні аспекти: дані можуть надходити у дискретному вигляді, що означає можливість наявності значної кількості унікальних значень; можуть містити викиди та шум, а також демонструвати явище "прокляття розмірності", яке включає аномальні викиди, що становлять виклик для більшості статистичних методів аналізу даних;
- Існуючі міри схожості, які застосовуються для кластеризації статичних даних, не завжди можна використовувати для часових рядів, оскільки дані, що надходять для обробки, часто мають різну довжину ряду.

Крім того, у багатовимірних часових рядах може бути перетин даних, що створює додаткові виклики для використання існуючих мір схожості.

Усі вище зазначені особливості, такі як велика розмірність, наявність шуму та висока кореляція, створюють потребу в розробці та вдосконаленні нових підходів для попередньої обробки даних та подальшого аналізу.

У класичних підходах, які найчастіше використовуються для кластеризації, дані для обробки надходять у повному вигляді, що означає, що часовий ряд розглядається як вибірка загалом, а не окремі спостереження. Спостереження об'єднуються у формі пакету та подаються на обробку в цілому. Такий підхід суттєво збільшує час обробки ряду та вимагає значних ресурсів для отримання нових результатів, що є проблематичним, особливо при роботі з обсягом спостережень, який часто характерний для часових рядів.

Для вирішення цієї проблеми можливим є використання алгоритмів обробки послідовностей даних у режимі онлайн, які дозволяють поступово обробляти дані, які надходять на вхід, замість обробки всього набору даних одночасно. Це може покращити ефективність та економію ресурсів у випадках, коли часові ряди мають значний обсяг спостережень.

Так само, як і у випадку статичної кластеризації даних, кластеризація часових рядів передбачає використання алгоритму або процедури для формування кластерів. Вибір конкретного алгоритму кластеризації залежить від типу доступних даних, визначеної мети та конкретного застосування. Дані часових рядів можуть бути різними: дискретними або неперервними, зі сталою або змінною частотою вибірок, одновимірними або багатовимірними, а також можуть мати однакову чи різну довжину.

На сьогоднішній день існує велика кількість алгоритмів кластеризації для послідовних даних. Незважаючи на різницю у підходах, всі ці методи мають спільну мету - модифікацію існуючих алгоритмів для статичних даних з метою обробки спостережень у формі часових рядів. Також часто вони спрямовані на трансформацію послідовних даних у статичні для можливості прямого використання методів кластеризації для статичних послідовностей.

Для кластеризації часових рядів можна виділити такі підходи:

- а) методи на сирих даних;
- б) методи на ознаках;
- в) методи на основі моделей.

Спочатку найбільш популярними алгоритмами для кластеризації часових рядів були методи, які працюють безпосередньо з сирими даними. Відмінною особливістю цих алгоритмів є вибір метрик подібності, спеціально призначених для роботи з послідовностями, відрізняючих їх від алгоритмів кластеризації статичних даних. Пізніше стали розвиватися алгоритми, які конвертують початкові дані у вектор ознак меншої розмірності або у кількість параметрів моделі. Після цього використовується сам алгоритм кластеризації, що призвело до виникнення методів на ознаках або на основі моделей для кластеризації часових рядів. На рисунку 3.12 зображено класифікація методів, які використовуються для кластеризації часових рядів.

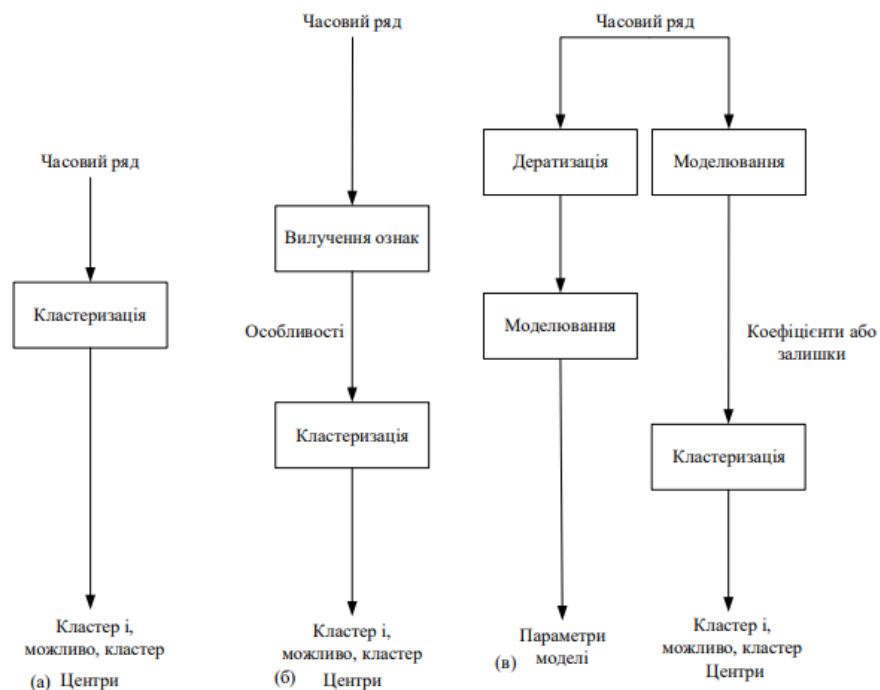


Рисунок 3.12 – Класифікація підходів до кластеризації часових рядів.

Джерело: [33]

Метод кластеризації К-середніх є популярним алгоритмом, застосовуваним для групування даних у кілька кластерів. Початково

обирається бажана кількість кластерів (K), і для кожного з них ініціалізуються випадкові центроїди. Наступною кроком є призначення кожного об'єкта даних до того кластера, центроїд якого є найближчим. Після цього обчислюються нові центроїди для кожного кластера, як середнє значення об'єктів, які до нього відносяться. Цей процес повторюється до збіжності, і в результаті отримуємо групи об'єктів, які схожі між собою у межах кластерів. Метод K -середніх ефективно використовується для різноманітних завдань, таких як сегментація клієнтів, аналіз зображень або вивчення структури даних.

K Means - це алгоритм кластеризації, який входить до складу бібліотеки `scikit-learn (sklearn)` у мові програмування `Python`. Цей алгоритм відноситься до неводільних методів кластеризації, тобто призначений для розділення набору даних на групи або "кластери" на основі схожості між їхніми елементами. Алгоритм K Means розділяє набір даних на K кластерів таким чином, щоб сума квадратів відстаней між точками у кожному кластері і центром кластера (центроїдом) була мінімальною. Це означає, що точки всередині кластера подібні між собою, а відстань між кластерами - максимальна.

В контексті даного дослідження, аналізувалися дані щодо обсягів продажів у 22 країнах протягом 7 років, з врахуванням місячної динаміки. Для групування подібних динамік продажів застосовувався алгоритм кластеризації K Means, в результаті чого було виявлено 6 кластерів. Цей підхід дозволив виявити та розпізнати схожі патерни та тенденції в розвитку ринків у розглянутий період. Були сформовані кластерні центроїди для кращого розуміння кластерів(рим 3.13). Реалізація представлена в Додатку Д.3

Перший кластер має одного представника країна Австрія можна охарактеризувати загальний тренд у часовому ряду досить стабільний від січня 2016 року до серпня 2022 року, з видимим збільшенням у серпні 2022 року. Є певна сезонність у даних. Наприклад, видно виражений спад у січні та лютому, пік влітку (особливо у червні) і знову спад у грудні. Часовий ряд не дуже довгий, тому циклічність може бути важко визначити.

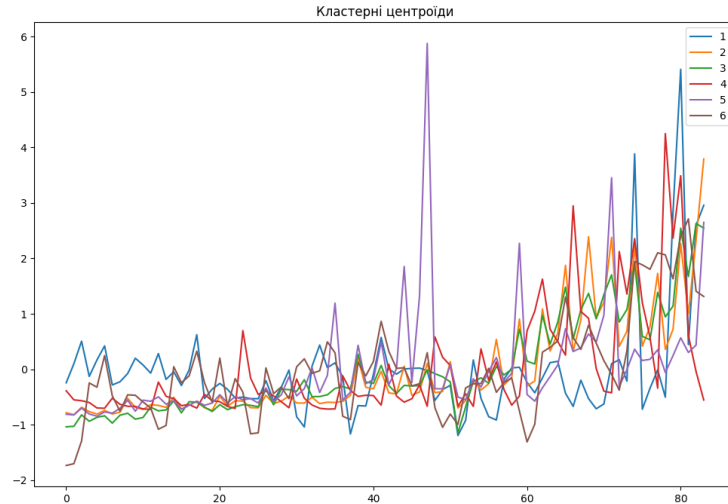


Рисунок 3.13 – Центроїди кластерів 22 країн

Проте, можна помітити певні періоди зростання та зниження, що може вказувати на наявність циклічності. Є декілька аномалій у даних, зокрема великі стрибки у січні 2016 року, червні 2018 року, квітні 2020 року, серпні 2022 року. Здається, що грудень має тенденцію бути місяцем з великими значеннями у кінці кожного року(рис.3.14).

Другий кластер представляє 9 країн представником другого кластера буде Великобританія(рис 3.15.). Характерним є загальний тренд у цьому часовому ряду досить виразний. Можна спостерігати поступове зростання значень від січня 2016 року до грудня 2022 року, з особливо великим зростанням у серпні 2022 року та вересні 2022 року. Є виражена сезонність у цих даних. Варто зазначити значні зростання влітку, особливо у червні та вересні, і менші значення взимку, особливо в січні та лютому. Враховуючи термін спостережень, важко визначити циклічність.

Проте, можна помітити кілька періодів зростання та зниження, що може вказувати на наявність циклічності. Є кілька аномалій у даних, зокрема різкі стрибки в березні 2020 року, вересні 2020 року, вересні 2021 року, березні 2022 року, вересні 2022 року та грудні 2022 року. Цей часовий ряд суттєво зростає в останні роки, з особливим акцентом на 2022 рік, де є кілька значних стрибків. Ввесь кластер представлено в Додатку В.



Рисунок 3.14 – Динаміка представника першого кластера



Рисунок 3.15 – Динаміка представника другого кластеру – Великобританія

Третій кластер представляє 8 країн представником третього кластера буде Польща (рис 3.16.). Характерним важко визначити виражений тренд, оскільки значення коливаються навколо середнього рівня. Є певна сезонність у даних, зокрема підвищення влітку та зменшення взимку. Найвищі значення спостерігаються в серпні та грудні, а найнижчі - в липні та лютому. З урахуванням обмеженого періоду часу важко визначити циклічність. Проте, можливо спостерігати певні періоди підвищення та зниження, які можуть бути пов'язані з іншими факторами. Є кілька аномалій, наприклад, різкі стрибки у грудні 2018 року, квітні 2021 року та грудні 2021 року. Важливо вивчити ці

точки для зрозуміння можливих причин. Загальний характер цього часового ряду досить непередбачуваний, і відсутній чіткий тренд або регулярні цикли. Цей часовий ряд виглядає як набір даних зі значними варіаціями. Третій кластер представлено в Додатку Г.



Рисунок 3.16 – Динаміка представника представника третього кластеру -
Польща

Четвертий кластер представляє Ірландія (рис 3.17). В цьому часовому ряді важко визначити виражений тренд, оскільки значення коливаються навколо середнього рівня. Можна виокремити деяку сезонність у даних, зокрема підвищення у січні та липні. Значення у липні мають тенденцію бути вищими, ніж у інших місяцях. Враховуючи обмежений часовий період, важко визначити циклічність. Можливо, спостерігається деяка непередбачувана коливання в деякі періоди. Є кілька аномалій, наприклад, різкі стрибки у січні 2017 року, січні 2019 року, травні 2020 року, липні 2021 року, січні 2022 року та липні 2022 року. Важливо вивчити ці точки для зрозуміння можливих причин. Загальний характер цього часового ряду досить непередбачуваний, і відсутній чіткий тренд або регулярні цикли.



Рисунок 3.17 – Динаміка представника четвертого кластеру

П'ятий кластер представляє Нідерланди (рис 3.18). Характерним у цьому часовому ряді спостерігається виражений тренд зі зростанням значень з часом. Загалом, можна визначити позитивний лінійний тренд. Можливо, спостерігається певна сезонність, особливо в липні та грудні, коли спостерігається значне підвищення значень. Враховуючи обмежений часовий період, важко визначити циклічність. Проте, можливо спостерігати деякі періоди зі зростанням та спаданням. Є кілька аномалій, таких як різкі стрибки у грудні 2018 року, липні 2019 року, грудні 2019 року та липні 2021 року. Важливо вивчити ці точки для зрозуміння можливих причин. Цей часовий ряд відрізняється великими значеннями в порівнянні з попередніми вказівниками, що може свідчити про зростання активності чи попиту.



Рисунок 3.18 – Динаміка представника п'ятого кластер

Шостий і останній кластер представляє Канада (рис 3.19 – 3.20) в ньому також присутня Південна Корея. У цьому часовому ряді спостерігається

загальний тренд зростання значень з часом. Здається, що величина споживання зростає протягом років. Сезонність може бути помітною в певних місяцях, але вона не так виражена, як тренд зростання загальних значень. Аномалій, які виглядають як різкі стрибки або спади, в цьому часовому ряді не так багато. Загалом, патерн досить стабільний. Цей часовий ряд виглядає стабільним, і величина значень у порівнянні з іншими вказівниками може свідчити про сталість або навіть певний рівень насиченості.



Рисунок 3.19 – Динаміка представника представника шостого кластеру,
Канада



Рисунок 3.20 – Динаміка представника представника шостого кластеру,
Південна Корея

Для розуміння співвідношень будемо таблицю(табл. 3.1).

Таблиця 3.1 – Співставлення кластер країна

Кластер	Країна
Перший	Австралія
Другий	Великобританія, Німеччина, Данія, Італія, Норвегія, Фінляндія, Франція, Швейцарія, Швеція.
Третій	Австрія, Бельгія, Ізраїль, Іспанія, Китай, Польща, Португалія, США
Четвертий	Ірландія
П'ятий	Нідерланди
Шостий	Канада, Південна Корея.

Таблиця 3.2 – Результати прогнозу.

Представники кластерів	MAE	MSE	SMAPE	RMSE	MAPE
Австралія Кластер 1	1787.854	6830777.128	53.106	2613.576	38.082
Великобританія Кластер 2	7776.409	87374268.418	52.039	9347.42	69.035
Польща Кластер 3	191.224	57779.779	22.752	24.374	23.868
Ірландія Кластер 4	651.787	641004.112	210.713	800.627	219.249
Нідерланди Кластер 5	2663.448	14575500.196	66.494	3817.787	88.881
Канада Кластер 6	666,959	902748.356	8.969	950.131	9.769

Прогнозна модель представлена в Додатку Д рис.4. Механізм навчання прогновної моделі з використанням KerasTuner представлено в Додатку Д

рис.5. Аналізуючи дані в таблиці для шести країн кластерів (Австралія, Великобританія, Польща, Ірландія, Нідерланди, Канада), можемо виділити деякі ключові спостереження. Мінімальне значення MAE спостерігається у кластері 3 (Польща) зі значенням 191.224, в той час як максимальне значення виявляється в кластері 2 (Великобританія) - 7776.409. Кластер 3 (Польща) також вирізняється найменшою квадратичною помилкою (57779.779), але кластер 2 (Великобританія) має найбільше значення MSE - 87374268.418. Кластер 6 (Канада) відзначається найменшою SMAPE (8.969%), тоді як кластер 4 (Ірландія) має найвищу SMAPE - 210.713%. Знову кластер 3 (Польща) показує найменшу кореневу квадратичну помилку (24.374), тоді як кластер 2 (Великобританія) - найбільшу зі значенням 9347.42. Кластер 6 (Канада) володіє найменшою відсотковою помилкою MAPE (9.769%), у той час як кластер 4 (Ірландія) має найвищу MAPE - 219.249%. Загально, кластер 3 (Польща) виявився точнішим залишковим кластером, тоді як кластер 2 (Великобританія) має великі значення помилок, що може вказувати на значні розбіжності між прогнозами та фактичними значеннями. Кластер 6 (Канада) та деякі інші кластери також виглядають відносно точними. Результати в графіках представлено в рисунках 3.20 – 3.25.




Рисунок 3.21 – Прогноз кластера 1, країна Австрія




Рисунок 3.22 – Прогноз кластера 2, країна Великобританія




Рисунок 3.23 – Прогноз кластера 3, країна Польща




Рисунок 3.24 – Прогноз кластера 4, країна Ірландія




Рисунок 3.25 – Прогноз кластера 4, країна Нідерланди




Рисунок 3.26 – Прогноз кластера 5, країна Канада

Проведений аналіз метрик для кластерів країн, які прогнозувалися у контексті часових рядів електротранспорту, дозволяє отримати докладний вигляд на якість прогнозів та їхню варіабельність в залежності від країн. Додаючи інформацію, що ці часові ряди є неоднорідними, гетерогенними та варіативними, можемо сформулювати додаткові висновки.

Кластер 3, що представляє Польщу, вирізняється найменшими значеннями помилок у всіх метриках, що може свідчити про високу точність прогнозу для цієї країни. З урахуванням неоднорідності та гетерогенності часових рядів електротранспорту, це може вказувати на ефективність моделювання в умовах варіативності даних.

Натомість, кластер 2, що відповідає Великобританії, має великі значення помилок у всіх метриках, що може свідчити про значні труднощі у прогнозуванні електротранспортних продажів в цій країні. Гетерогенність часових рядів може впливати на точність прогнозів, особливо якщо динаміка змін у цих рядах є непередбачуваною та змінною.

Кластер 6 (Канада), з найменшими відсотковими помилками SMAPE та MAPE, може свідчити про те, що модель добре пристосовується до варіативності цього часового ряду, що є важливим в умовах невизначеності.

Загалом, аналіз метрик у контексті прогнозування часових рядів електротранспорту підкреслює важливість розуміння та моделювання

гетерогенності та варіабельності даних для забезпечення точних та надійних прогнозів в умовах складних та змінних динамік.

У загальному контексті спостерігається позитивна динаміка у розширенні обсягу доступних даних та у поліпшенні якості прогнозу, на даний момент модель продемонструвала тільки самий базовий рівень ефективності, що обмежує нашу здатність аналізувати її потенціал. Невдовзі можна виокремити перспективи та значний потенціал в подальшому вдосконаленні. Важливо відзначити, що вже на даний момент можна врахувати зручність та обраний напрямок досліджень. Однак варто відзначити, що моделювання архітектури системи є завданням високої складності та тривалості. Створення та оптимізація механізму прогнозування вимагають високого рівня кваліфікації в області програмування, вищої математики, а також специфічних знань у сфері розвитку та налагодження нейромережових алгоритмів. Такі труднощі підкреслюють необхідність працювати та розвиватись в цій сфері для подальших розробок та ефективнішого використання ресурсів.

ВИСНОВКИ

Підсумовуючи можна говорити про необхідність підтримувати та адаптувати підтримку електромобілів та розвитку їх ринку. Початкова залежність від прямих субсидій повинна зменшитися, прокладаючи шлях до нейтральних для бюджету програм збору. Такі програми, що оподатковують неефективні транспортні засоби з двигунами внутрішнього згоряння для фінансування стимулів для купівлі автомобілів з низьким рівнем викидів або електромобілів (EV), є стратегічною політикою перехідного періоду. Глобальне прийняття суворих стандартів ефективності транспортних засобів та викидів CO₂ стає ключовим фактором для прискорення переходу на електротранспорт.

З огляду на глобальну ситуацію, існує нагальний заклик сприяти впровадженню електромобілів у країнах з перехідною економікою та країнах, що розвиваються. Пріоритетна електрифікація дво-триколісних транспортних засобів та міських автобусів, які є економічно вигідними, повинна бути на першому плані. Це вимагає комплексного підходу, що охоплює цінові сигнали, наявність зарядної інфраструктури та всеосяжні політичні рамки.

Важливо, що розширення інфраструктури електромобілів і розвиток "розумних" електромереж стають основоположними елементами. Уряди повинні продовжувати підтримувати загальнодоступну зарядну інфраструктуру доти, доки на дорогах не з'явиться критична маса електромобілів. Забезпечення рівного доступу до зарядних станцій, як за допомогою нормативних актів, так і фіскальної політики, має першорядне значення для того, щоб жодна громада не залишилася осторонь. Заохочення встановлення домашніх зарядних пристроїв та обов'язкове забезпечення готовності до зарядки електромобілів у нових будівлях є практичними кроками. Скоординовані зусилля з розширення електромереж у поєднанні з цифровими технологіями, що полегшують комунікацію та ціноутворення між електромобілями та електромережами, мають вирішальне значення для перетворення електромобілів на стабілізуючу силу для електромережі, а не на

виклик. Отже, еволюція електричної мобільності вимагає багатогранного та адаптивного політичного підходу для сприяння

Представлена робота є продуктом наукового дослідження, спрямованого на аналіз, нейромережевого моделювання та прогнозування часових рядів, що відзначаються нелінійністю та неоднорідних. Також розроблено індивідуальну нейромережеву модель ансамблевого типу, яка дозволяє отримувати прогнозні результати на основі реальних статистичних даних. У цьому дослідженні була створена модель, що базується на економічних даних продажу електротранспорту в 22 країнах за семирічний період з місячними інтервалами.

Під час виконання роботи було розроблено індивідуальну нейромережеву модель ансамблевого типу, побудовано механізм автоматичного збільшення даних для навчання нейромережі, використано рекурентні моделі в частоті LSTM, GRU та методики ансамблевого типу на базі методів бустинг та бегінг. Проведено аналіз тестових даних на наявність нелінійності, неоднорідності. Здійснено графічну візуалізацію побудованих моделей на тестовій та валідаційній вибірках та в порівняльному режимі. Перевірено адекватність побудованих моделей за допомогою критеріїв адекватності та зроблено висновки щодо якості оцінювання прогнозу. Отримані результати та самі прогнози на декілька кроків вперед імплементовано у графіки, які демонструють майбутню тенденцію поведінки розглянутих часових рядів.

Кожен з розглянутих методів виявляє свої обмеження та недоліки. Досягненням в цьому контексті є можливість подолання обмежень шляхом вибору відповідних методів прогнозування для конкретних областей. Проектуючи майбутню архітектуру, можна розглядати можливість комбінування цих методів та моделей для досягнення більш точних результатів та обґрунтованих висновків. У моєму дослідженні я оцінив різні методи прогнозування як класичні так і нейромережеві. Дослідникам надається можливість визначити найкращий метод, який дозволить

передбачити ситуацію на ринку електротранспорту з вищою точністю, ніж за допомогою раніше використовуваних методів.

З метою удосконалення майбутніх досліджень економічних процесів рекомендується розглянути застосування інших нейромережевих моделей як регресійного так і інших напрямків аналізу та їх модифікованих варіантів, а також використання ансамблю таких методів. Для отримання більш повної картини можливо розглянути введення пояснювальних змінних, що відобразатиме вплив різних параметрів нейромережевого програмування на результат. Також варто дослідити інші методи нейромережевого моделювання, такі як:

- а) мережа з радіальними базисними функціями;
- б) нейронні мережі, що самонавчаються;
- в) мережі адаптивної резонансної теорії;
- г) ймовірнісні нейронні мережі;
- д) та інші методи взаємодії з великими об'ємами даних.

Для поліпшення вибору моделі рекомендується розширити кількість рівнів перевірки адекватності моделювання та якості прогнозу. Врахування максимальної та мінімальної абсолютної похибки, а також застосування методу максимальної правдоподібності сприятиме більш об'єктивному вибору оптимальної моделі.

ПЕРЕЛІК ДЖЕРЕЛ ТА ПОСИЛАНЬ

1. Global EV Outlook 2022. *IEA webstore* : веб-сайт. URL: <https://www.iea.org/reports/global-ev-outlook-2022> (date of access: 25.09.2023).
2. Ширяєва Н. В., Клепіков Д. С. Дослідження ринку електромобілів та перспективи його розвитку. *Економіка, фінанси, облік, менеджмент і право в Україні та світі* : зб. тез допов. Міжнар. наук.-практ. конф., 1 груд. 2018 р. : у 6 ч. Ч. 2. Полтава : ЦФЕНД, 2018. С. 42–44.
3. Crist, Philippe. Electric vehicles revisited: Costs, subsidies and prospects. *International Transport Forum Discussion Paper*, No. 2012-3. URL: <https://doi.org/10.1787/5k8zv7h9lq7-en>.
4. European vehicle market statistics. Pocketbook 2013 / ed. by Dr. Peter Mock. Berlin : ICCT, 2013. 117 p. URL: https://theicct.org/sites/default/files/publications/EU_vehiclemarket_pocketbook_2013_Web.pdf (date of access: 10.10.2023).
5. Electric light commercial vehicles: Are they the sleeping giant of electromobility? / Anastasios Tsakalidis et all. *Transportation Research Part D: Transport and Environment*. Vol. 86, Sept. 2020. URL: <https://doi.org/10.1016/j.trd.2020.102421>.
6. Todd J., Chen J., and F.Clogston. Creating the Clean Energy Economy: Analysis of the Electric Vehicle Industry. Wasington : International Economic Development Council, 2013. 24 p. URL: https://www.iedconline.org/clientuploads/Downloads/edrp/IEDC_Electric_Vehicle_Industry_Summary.pdf (date of access: 15.10.2023).
7. Новотарський М. А., Нестеренко Б. Б. Штучні нейронні мережі: обчислення. *Праці Інституту математики НАН України*. Київ, 2004. 408 с.
8. Терейковський І. А., Бушуєв Д. А., Терейковська Л. О. Штучні нейронні мережі: базові положення : навч. посіб. Київ : КПІ ім. Ігоря Сікорського, 2022. 123 с.

9. Yahoo Finance : website. URL: <https://finance.yahoo.com/> (date of access: 15.10.2023).
10. Чернодуб А. М. Навчання рекурентних нейронних мереж методом псевдорегуляризації для багатокрокового прогнозування часових рядів. *Математичні машини і системи*. 2012. № 4. С. 41–51.
11. Matplotlib : website. URL: <https://matplotlib.org/> (date of access: 20.10.2023).
12. API TensorFlow : website. URL: <https://www.tensorflow.org/> (date of access: 23.10.2023).
13. API Keras : website. URL: <https://keras.io> (date of access: 26.10.2023).
14. API scikit-learn : website. URL: <https://scikit-learn.org/> (date of access: 27.10.2023).
15. NumPy : website. URL: <https://numpy.org/> (date of access: 28.10.2023).
16. Pandas : website. URL: <https://pandas.pydata.org/> (date of access: 29.10.2023).
17. Найпопулярніші електромобілі в світі. *Британська аналітична фірма JATO Dynamics* : веб-сайт. URL: https://twitter.com/JATO_Dynamics (дата звернення: 05.11.2023).
18. Звіт про доходи компанії Tesla Inc (TSLA). *Investing.com* : веб-сайт. URL: <https://ru.investing.com/equities/tesla-motors-income-statement> (дата звернення: 07.11.2022).
19. Берзлев О. Ю. Сучасний стан інформаційних систем прогнозування часових рядів. *Управління розвитком складних систем*. 2013. Вип. 13. С. 78–82. URL: <http://urss.knuba.edu.ua/files/zbirnyk-13/78-82.pdf> (дата звернення: 11.11.2023).
20. Нейромережа – що це таке, як працює та навіщо потрібна. *Termin.in.ua* : веб-сайт. URL: https://termin.in.ua/neyromerezha/#Bazova_struktura_ta_komponenti_neyromerezi (дата звернення: 15.11.2023).

21. Kurkula S., Maksyshko N., Ocheretin D., Cheverda S. Nonlinear dynamics of electric vehicle sales in China: a fractal analysis. *CEUR Workshop Proceedings*. 2023, 3465, PP. 206–221. URL: <https://ceur-ws.org/Vol-3465/paper21.pdf>.
22. Візуалізація продажів по всьому світу електрокарів. *Visualcapitalist* : веб-сайт. URL: <https://www.visualcapitalist.com/> (дата звернення: 15.11.2023).
23. Аргун Щ. В., Гнатов А. В., Ульянец О. А. Екологічний та енергоефективний електромобільний транспорт та його інфраструктура. *Вісник ЖДТУ*. 2016. № 2(77). С. 18–26.
24. Electric cars fend off supply challenges to more than double global sales. *IEA webstore* : website. URL: <https://www.iea.org/commentaries/electric-cars-fend-off-supply-challenges-to-more-than-double-global-sales> (date of access: 15.11.2023).
25. Gorban A. N., Waxman Cory. Neural Networks For Political Forecast. *WCNN'95: Proceedings of the World Congress on Neural Networks*, Washington DC, USA, July 1995. Pp. 176–178.
26. The uptake of plug-in hybrid electric vehicles in europe's company car fleets: trends and policies. *The International Council on Clean Transportation webstore* : website. URL: <https://theicct.org/the-uptake-of-plug-in-hybrid-electric-vehicles-in-europes-company-car-fleets-trends-and-policies/> (date of access: 17.11.2023).
27. Геєць В. М., Клебанова Т. С. Черняк О. І. Моделі і методи соціально-економічного прогнозування : підручник. Харків : ВД «ІНЖЕК». 2005. 396 с.
28. Christopher Olah: Understanding LSTM Networks. URL: <http://colah.github.io/posts/2015-08-Understanding-LSTMs/> (date of access: 17.11.2023).

29. Park, J., Yi, D. and S. Ji. Analysis of Recurrent Neural Network and Predictions. *Discrete Mathematics and Symmetry*. 2020, 12 (4), 615. URL: <https://doi.org/10.3390/sym12040615>.
30. Jason Brownlee. Time Series Prediction with LSTM Recurrent Neural Networks in Python with Keras base. URL: <https://machinelearningmastery.com/time-series-prediction-lstm-recurrent-neural-networks-python-keras/> (date of access: 18.11.2023).
31. Боровіков В. STATISTICA: мистецтво аналізу даних на комп'ютері. Для професіоналів. СПб: Пітер, 2001. 656 с. (рос.)
32. Субботін С. О., Олійник А. О. Нейронні мережі: навч. посіб. / за ред. С. О. Субботіна. Запоріжжя : ЗНТУ, 2014. 132 с.
33. Van Veen, F. & Leijnen, S. (2019). The Neural Network Zoo. URL: <https://www.asimovinstitute.org/neural-network-zoo> (date of access: 20.11.2022).
34. Добровська Л. М., Добровська І. А. Теорія та практика нейронних мереж : навч. посіб. Київ : НТУУ «КПІ». Вид-во «Політехніка», 2015. 396 с.
35. Шарапов О. Д., Дербенцев В. Д., Семьонов Д. Є. Економічна кібернетика : навч. посіб. Київ : КНЕУ, 2004. 231 с.
36. Бідюк П. І. Системний підхід до прогнозування на основі моделей часових рядів. *Системні дослідження та інформаційні технології*. 2003. № 3. С. 88–110.
37. API Python: website. URL: <https://www.python.org/> (date of access: 21.11.2022).
38. Kohonen, Teuvo. Self-organized formation of topologically correct feature maps. *Biological cybernetic*, 1982. Vol. 43.1. Pp. 59–69. URL: <https://tcosmo.github.io/assets/soms/doc/kohonen1982.pdf>.
39. TensorFlow: A System for Large-Scale Machine Learning / Martín Abadi et al. 12th USENIX Symposium on *Operating Systems Design and Implementation (OSDI'16)*, Nov. 2–4, 2016, Savannah, GA, USA. Pp. 265–283. URL: <https://www.usenix.org/system/files/conference/osdi16/osdi16-abadi.pdf> (date of access: 21.11.2023).

40. Класифікація штучних нейромереж : веб-сайт. URL: https://termin.in.ua/neyromerezha/#Bazova_struktura_ta_komponenti_neyromerezi (дата звернення: 25.11.2023).

41. Штурмак Є. В., Максишко Н. К. Аналіз застосування альтернативних моделей нейро-мережі для прогнозування. *Управління соціально-економічним розвитком регіонів і держави* : зб. матеріалів XVII Міжнар. наук.-практ. конф., Запоріжжя, 20-21 квіт. 2023 р. / за ред. А. В. Череп. Запоріжжя : ЗНУ, 2023. С. 215–218.

ДОДАТОК А

Характеристики динаміки світового ринку електромобілів




Рисунок А.1 - Динаміка обсягів продажів електрокарів на світовому ринку за період з 2010 по 2021 рр.

Джерело: [1]




Рисунок А.2 – Кількість точок зарядки на електромобіль і кВт на електричний LDV в окремих країнах, 2021 рік.

Джерело: [1]

ДОДАТОК Б

Види нейромеревих архітектур

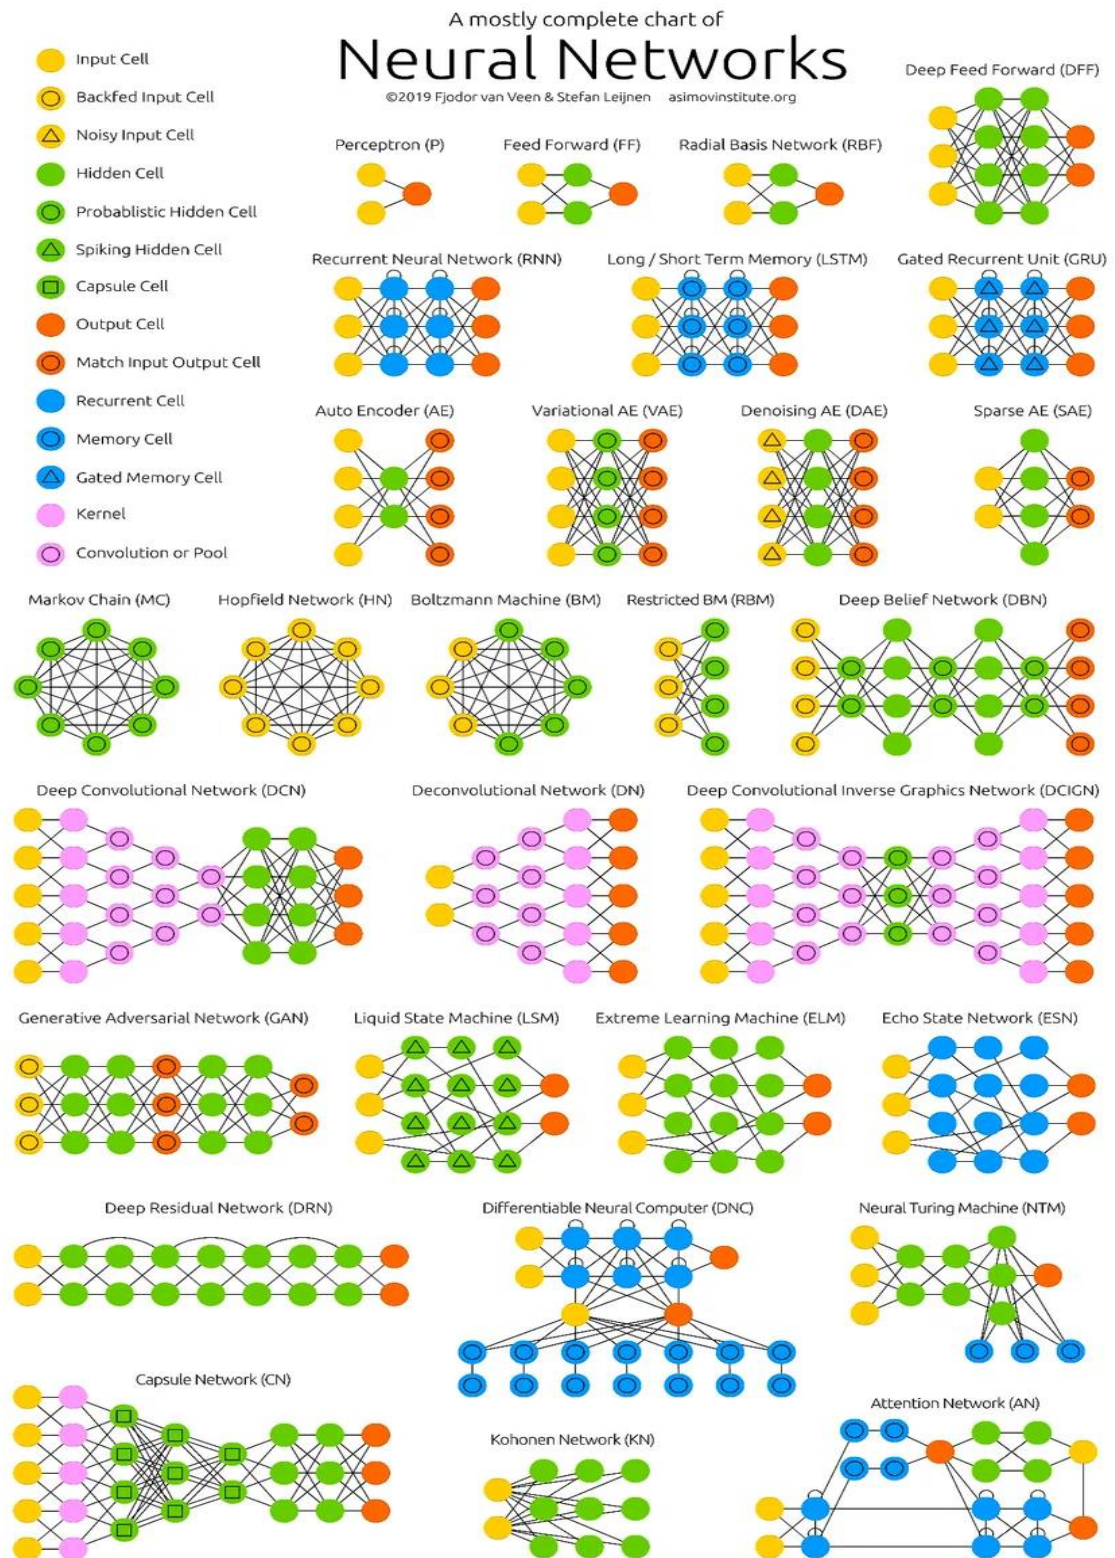


Рисунок В.1 – Різновиди архітектур нейромерев

Джерело: [41]

ДОДАТОК В

Динаміка обсягів продажів електромобілів: Кластер 2



Рисунок А.1 – Продажі

Великобританія 2016 – 2022 рр.



Рисунок А.2 – Продажі Німеччина

2016 – 2022 рр.



Рисунок А.3 – Продажі Данія 2016

– 2022 рр.



Рисунок А.4 – Продажі Італія 2016 –

2022 рр.



Рисунок А.5 – Продажі Норвегія

2016 – 2022 рр.



Рисунок А.6 – Продажі Фінляндія

2016 – 2022 рр.



Рисунок А.7 – Продажі Франція
2016 – 2022 рр.



Рисунок А.8 – Продажі Швейцарія
2016 – 2022 рр.



Рисунок А.9 – Продажі Швеція 2016 – 2022 рр.

ДОДАТОК Г

Динаміка обсягів продажів електромобілів: Кластер 3



Рисунок Б.1 – Продажі Австралія 2016 – 2022 рр.



Рисунок Б.2 – Продажі Бельгія 2016 – 2022 рр.




Рисунок Б.3 – Продажі Ізраїль 2016 – 2022 рр.




Рисунок Б.4 – Продажі Іспанія 2016 – 2022 рр.



Рисунок Б.5 – Продажі Китай 2016 – 2022 рр.



Рисунок Б.6 – Продажі Польща 2016 – 2022 рр.



Рисунок Б.7 – Продажі Португалія
2016 – 2022 рр.




Рисунок Б.8 – Продажі США 2016 –
2022 рр.

ДОДАТОК Д

Реалізація моделі в Python

```
import requests as req
from bs4 import BeautifulSoup
import yfinance as yf
import pandas as pd
import numpy as np
import matplotlib.pyplot as plt

import os

r = req.get('https://finance.yahoo.com/commodities').text
soup = BeautifulSoup(r, 'lxml')
tickers = soup.find('section', id="yfin-list").find('tbody').find_all('tr')
ticker_futures = []

for tiker in tickers:
    tiker = tiker.find('td').text
    if tiker != '':
        ticker_futures.append(tiker)

tickers = yf.Tickers(ticker_futures)
DF_tickers = pd.DataFrame()
```

Рисунок Д.1 – Парсинг тікерів з сайту Yahoo Finance

```

def pars_in_Df(ticker_list):
    def get_info(ticker_obj):
        info_keys = ['shortName', 'underlyingSymbol', 'sector']
        info_values = []
        for key in info_keys:
            info_values.append(ticker_obj.info.get(key, None))
        return dict(zip(info_keys, info_values))

    df_tickers = []
    save = './Date/Df_tickers_TM/'
    period = '5y'
    for ticker in ticker_list:
        try:
            ticker_obj = yf.Ticker(ticker)
            close_price = tickers.tickers[ticker].history(period=period)['Close']
            for count in close_price:
                if count == (0 or np.NaN):
                    raise isNaN()

            info = get_info(ticker_obj)
            info.update(close_price.to_dict())
            df_tickers.append(info)
        except Exception as exc:
            print(exc)
            continue

    DF_tickers = pd.DataFrame(df_tickers, index=None)

    start = str(DF_tickers.columns[1]).split(' ')[0].split('-')[0]
    end = str(DF_tickers.columns[-1]).split(' ')[0].split('-')[0]
    date = f'

    DF_tickers.to_csv(save+f'Df_ticker_{period}.csv', index=False)

```

Рисунок Д.2 – Створення дата сету з сайту Yahoo Finance

```

distortions = []
silhouette = []
K = range(1, 10)
for k in tqdm(K):
    kmeanModel = TimeSeriesKMeans(n_clusters=k, metric="euclidean", n_jobs=6, max_iter=10)
    kmeanModel.fit(tickers_scaled)
    distortions.append(kmeanModel.inertia_)

|

0% | 0/9 [00:00<?, ?it/s]

n_clusters = 6
ts_kmeans = TimeSeriesKMeans(n_clusters=n_clusters, metric="euclidean", n_jobs=3, max_iter=10)
ts_kmeans.fit(tickers_scaled)

```

Рисунок Д.3 – Реалізація механізму кластеризації

```

1 def bild_model(hp):
2     n = 2
3     model_HP = Sequential(name='model_tuner')
4     model_HP.add(LSTM(units=hp.Int(name='units',
5         min_value=32 * n,
6         max_value=126 * n,
7         step=32 * n,
8         default=64 * n
9         ),
10        activation=hp.Choice(name='LSTM_1_activation',
11            values=['relu', 'tanh', 'sigmoid', "linear"],
12            default='relu'),
13        return_sequences=False,
14        input_shape=(12, 1)
15        ))
16
17
18     model_HP.add(Dropout(rate=hp.Float(name='dropout',
19         min_value=0.0,
20         max_value=0.5,
21         default=0.2,
22         step=0.05)
23        ))
24
25     model_HP.add(Dense(TEST_LEN, activation='linear'))
26     model_HP.compile(
27         optimizer=Adam(0.01),
28         loss='mae',
29         metrics=['mse']
30     )

```

Рисунок Д.4 – реалізація моделі для прогнозування

```
1 model_HP = BayesianOptimization(  
2     hypermodel=bild_model,  
3     objective="val_loss",  
4     max_trials=10,  
5     directory='save_tuner',  
6     overwrite=True  
7 )
```

а)

```
2 model_HP.search(  
3     x_train,  
4     y_train,  
5     epochs=25,  
6     batch_size=12,  
7     verbose=1,  
8     validation_split=0.3,  
9     shuffle=False  
10 )  
11 model = model_HP.get_best_models(1)  
12 model_cluster_0 = model[0]  
13 model[0].summary()
```

б)

Рисунки Д.5 – Опис процедури реалізації механізму навчання KerasTuner:

а) Використання Баєсовської оптимізації для забезпечення оптимальними параметрами моделі;

б) Механізм навчання прогнозної моделі та вибору найкращої із представлених в пункті «а».

Декларація академічної доброчесності
здобувача вищої освіти ЗНУ

Я Штурмак Євгеній Валерійович, студент(ка) другого курсу,
форми навчання зочна, факультету економічного,
спеціальності 051 Економіка,
адреса електронної пошти evgenijsturmak@gmail.com,

- підтверджую, що написана мною кваліфікаційна робота на тему «Застосування нейромережного моделювання для прогнозування динаміки продажів на ринку електромобілів» відповідає вимогам академічної доброчесності та не містить порушень, що визначені у ст. 42 Закону України «Про освіту», зі змістом яких ознайомлений/ознайомлена;
- заявляю, що надана мною для перевірки електронна версія роботи є ідентичною її друкованій версії;
- згоден/згодна на перевірку моєї роботи на відповідність критеріям *академічної доброчесності у будь-який спосіб, у тому числі за допомогою Інтернет-системи*, а також на архівування роботи в базі даних цієї системи.

Дата _____ Підпис _____ ПІБ (студент) Штурмак Є.В.

Дата _____ Підпис _____ ПІБ (наук. керівник) Макшишко Н.К.