

Міністерство освіти і науки України
Кам'янець-Подільський національний університет імені Івана Огієнка
Фізико-математичний факультет
Кафедра комп'ютерних наук

Дипломна робота
магістра

**з теми: «ШТУЧНІ НЕЙРОННІ МЕРЕЖІ ТА ЇХ ЗАСТОСУВАННЯ В
ЗАДАЧАХ ПРОГНОЗУВАННЯ»**

Виконав: здобувач вищої освіти
2 курсу, групи КН1-М22
спеціальності 122 Комп'ютерні науки
Козаков Віталій Вікторович

Керівник: **Пилипюк Т.М.**,
кандидат фізико-математичних наук,
доцент, доцент кафедри комп'ютерних наук

Рецензент: **Газдюк К.П.**,
доктор філософії з інженерії програмного
забезпечення, доцент, асистент кафедри
програмного забезпечення комп'ютерних
систем Чернівецького національного
університету імені Юрія Федьковича

Кам'янець-Подільський – 2023

ЗМІСТ

ВСТУП	3
РОЗДІЛ 1. ТЕОРЕТИЧНІ ОСНОВИ ШТУЧНИХ НЕЙРОННИХ МЕРЕЖ	5
1.1. Поняття штучної нейронної мережі.....	5
1.2. Історія розвитку галузі штучних нейронних мереж.....	11
1.3. Архітектура з'єднань штучних нейронних мереж та їх типи.....	14
1.4. Навчання штучних нейронних мереж.....	28
Висновки до розділу 1.....	32
РОЗДІЛ 2. ДОСЛІДЖЕННЯ ЗАДАЧ ПРОГНОЗУВАННЯ ЗА ДОПОМОГОЮ ШТУЧНИХ НЕЙРОННИХ МЕРЕЖ	33
Висновки до розділу 2.....	48
РОЗДІЛ 3. ПРАКТИЧНА ЧАСТИНА: ПРОГНОЗУВАННЯ НА РИНКУ ПАЛЬНОГО	49
3.1. Актуальність та фактори, що впливають на ціноутворення.....	49
3.2. Вхідні дані для дослідження.....	52
3.3. Результати дослідження.....	54
ВИСНОВКИ	59
СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ	61
ДОДАТКИ	66

ВСТУП

У наші дні управління на основі аналізу зовнішніх ситуацій (подій) залишається однією із ключових ідей інтелектуального управління. Інтелектуальні системи останнім часом стали досить розповсюдженим комерційним продуктом, що знаходить широкий попит користувачів-фахівців у найрізноманітніших областях інженерно-технічної й науково-технічної сфер діяльності.

Штучні нейронні мережі (ШНМ) – галузь не нова, але активно розвивається та стає з часом все популярнішою та затребуваною.

Актуальність теми. Актуальність розробок в галузі нейронних мереж обумовлена перш за все тим, що застосування даної моделі широко використовуються в найрізноманітніших областях. За допомогою вирішення задач на основі нейронних мереж функціонування будь-якої системи стає ефективнішим. Сьогодні відома велика кількість галузей застосування штучних нейронних мереж. Найбільш розповсюдженими серед них є: фінанси, економіка, медицина, наукові дослідження, інформаційні технології, штучний інтелект та ін. Необхідно зазначити, що існує велика кількість програмного забезпечення, яке використовує можливості технологій штучних нейронних мереж. Нейронні мережі увійшли в практику всюди, де потрібно вирішувати завдання прогнозування, класифікації, розпізнавання, тощо.

Одним з напрямів практичного використання ШНМ є задачі прогнозування, а саме: прогнозування курсу валют, побудова прогнозу споживання електроенергії, прогнозування платоспроможності кредиторів, навантаження енергетичних систем та ін. ШНМ можуть застосовуватися для вирішення практично будь-якого роду задач, зокрема і за відсутності явної математичної моделі чи за нестачі даних задля ефективного застосування статистичних методів.

Через те, що у сучасному світі все з більшою гостротою проявляється інтерес до якісного прогнозування, що пов'язано з швидким розвитком високих технологій і, відповідно, з появою нових інструментів аналізу даних, одним з найактуальніших досліджень є саме прогнозування.

Метою даної роботи є дослідження штучних нейронних мереж та можливість їх використання в задачах прогнозування.

Завдання дослідження:

- здійснити огляд та аналіз джерел з теми дослідження;
- розкрити теоретичні основи штучних нейронних мереж;
- здійснити дослідження задач прогнозування з використанням штучних нейронних мереж, методи їх проектування та навчання.

Об'єкт дослідження. Задачі прогнозування.

Предмет дослідження. Застосування нейромережових алгоритмів для прогнозування.

Методи дослідження. Метод аналізу та синтезу, систематизація знань та метод наукового пізнання.

Апробація результатів дослідження. Результати досліджень були оприлюднені на звітній науковій конференції здобувачів вищої освіти 1 листопада 2023 року та опубліковані у збірнику матеріалів наукової конференції здобувачів вищої освіти фізико-математичного факультету Кам'янець-Подільського національного університету імені Івана Огієнка [7]. Статтю «Штучні нейронні мережі та їх застосування в задачах прогнозування» за результатами дослідження у співавторстві з науковим керівником опубліковано у Віснику Кам'янець-Подільського національного університету імені Івана Огієнка. Фізико-математичні науки. Випуск 16 [8].

Структура роботи. Магістерська робота складається із вступу, трьох розділів, висновків, списку використаних джерел і додатку.

РОЗДІЛ 1. ТЕОРЕТИЧНІ ОСНОВИ ШТУЧНИХ НЕЙРОННИХ МЕРЕЖ

1.1. Поняття штучної нейронної мережі

Штучні нейронні мережі (ШНМ) – це математичні моделі, а також їх програмні або апаратні реалізації, побудовані за принципом організації й функціонування біологічних нейронних мереж – мереж нервових кліток живого організму або простіше кажучи це спроба відтворення роботи людського мозку на комп'ютері за допомогою шарів нейронів. Нейронні мережі не програмуються у звичному змісті цього слова, вони навчаються. Можливість навчання – одне з головних переваг нейронних мереж перед традиційними алгоритмами. З цього і випливає визначення штучного інтелекту можливість машини або програми знаходити рішення за допомогою обчислень.

Вивчаючи тематику штучних нейронних мереж, можна провести аналогію із мозком людини, бо саме розвиток штучних нейронних мереж надихався дослідженнями в області біології та анатомії, а саме роботі і функціонуванні головного мозку людини.

При розгляді мережевих конфігурацій та їх розробок вчені роблять акцент на термінах із біології, які характеризують організацію мозкової діяльності людини чи інших істот. Наші знання про роботу мозку дуже обмежені, оскільки людство ще не до кінця провело дослідження в цій області і не знає багатьох нюансів, тому розроблювачам мереж приходится виходити за межі сучасних біологічних знань у пошуках структур, здатних виконувати корисні функції.

Базовим елементом мозку людини є нейрони – специфічні клітини, що здатні запам'ятовувати і застосовувати попередній досвід до наступних дій, що докорінно відрізняє їх від інших клітин організму. Кора головного мозку людини є протяжною, утвореною нейронами поверхнею товщиною від 2 до 3 мм із площею близько 2200 см², що вдвічі перевищує площу поверхні

стандартної клавіатури. Кора головного мозку містить близько 10^{11} нейронів, що приблизно дорівнює числу зірок Чумацького шляху. Кожен нейрон зв'язаний з 10^3 – 10^4 іншими нейронами. У цілому мозок людини містить приблизно від 10^{14} до 10^{15} взаємозв'язків. Потужність людського розуму залежить від числа базових компонентів, різноманіття з'єднань між ними, а також від генетичного програмування й навчання. Окремий нейрон є складним, має свої складові, підсистеми та механізми керування і передає інформацію через велику кількість електрохімічних зв'язків. Налічують біля сотні різних класів нейронів. Разом нейрони та з'єднання між ними формують недвійковий, нестійкий та несинхронний процес, що відрізняється від процесу обчислень традиційних комп'ютерів. Штучні нейромережі моделюють лише найголовніші елементи природного мозку, але надихають науковців та розробників до пошуку нових шляхів розв'язування проблеми. Щоб почати далі досліджувати штучні нейронні мережі потрібно спочатку зрозуміти їх природу і походження, а також дати визначення біологічного нейрону.

Біологічний нейрон складається з тіла клітини – соми, і двох типів зовнішніх деревоподібних відгалужень: аксон і дендритів. Тіло клітини вміщує ядро, що містить інформацію про властивості нейрона, і плазму, яка продукує необхідні для нейрона матеріали. Нейрон отримує сигнали (імпульси) від інших нейронів через дендрити (приймачі) і передає сигнали, що згенеровані тілом клітки, вздовж аксона (передавач), який наприкінці розгалужується на волокна. На закінченнях волокон знаходяться синапси. На рисунку 1.1. наведена схема біологічного нейрону.




Рис. 1.1. Схема біологічного нейрону

Синапс є функціональним вузлом між двома нейронами (волокно аксона одного нейрона і дендрит іншого). Коли імпульс досягає синаптичного закінчення, там продукуються хімічні речовини – нейротрансмітери. Нейротрансмітери проходять через синаптичну щілину і в залежності від типу синапсу, збуджують або гальмують здатність нейрона-приймача генерувати електричні імпульси. Результативність синапсу налаштовується сигналами, які проходять скрізь нього, тому синапси навчаються у відповідності до активності процесів, у яких вони приймають участь. Нейрони взаємодіють за допомогою короткої серії імпульсів, повідомлення передається за допомогою частотно-імпульсної модуляції. Біологічні нейрони є структурно складнішими, ніж існуючі штучні нейрони. Оскільки нейрофізіологія надає науковцям розширене розуміння дії нейронів, а технологія обчислень постійно вдосконалюється, розробники мереж мають необмежений простір для вдосконалення моделей.

Тепер можемо описати структуру штучного нейрону. Штучний нейрон є базовим модулем нейронних мереж. Він моделює основні функції природного нейрона. Штучний нейрон складається з помножувачів (синапсів), суматора і нелінійного перетворювача. Синапси призначені для

зв'язку нейронів між собою і множать вхідний сигнал x_i на деяке постійне число. Це число w_i , назване вагою синапса, характеризує силу цього зв'язку. Суматор виконує додавання всіх сигналів, що надходять на вхід нейрона від інших нейронів, і зовнішніх вхідних сигналів. Нелінійний перетворювач призначений для нелінійної зміни вихідного значення суматора відповідно до деякої функції від одного аргументу. Ця функція називається функцією активації чи передатною функцією нейрона. При функціонуванні нейрон одночасно отримує багато вхідних сигналів. Кожен вхід має свою власну синаптичну вагу, яка надає входу вплив, необхідний для функції суматора елемента обробки. Ваги є мірою сили вхідних зв'язків і моделюють різноманітні синаптичні сили біологічних нейронів. Ваги суттєвого входу підсилюються і, навпаки, вага несуттєвого входу примусово зменшується, що визначає інтенсивність вхідного сигналу. Ваги можуть змінюватись відповідно до навчальних прикладів, топології мережі та навчальних правил. Вхідні сигнали x_n зважені ваговими коефіцієнтами з'єднання w_n додаються, проходять через передатну функцію, генерують результат і виводяться. На рисунку 1.2. наведено базовий штучний нейрон.

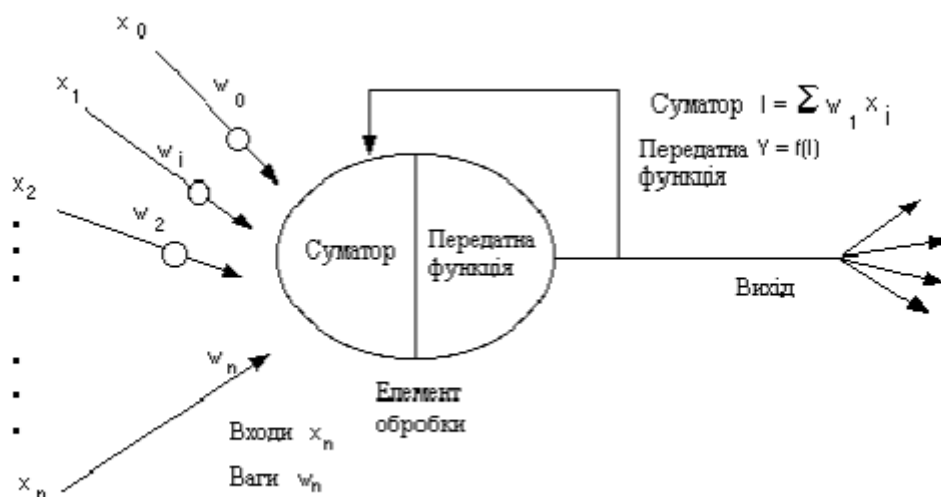


Рис. 1.2. Базовий штучний нейрон

В програмних реалізаціях штучні нейрони називають «елементами обробки» або «процесорами» і вкладають в них більше можливостей, ніж в базовому штучному нейроні, що описаний вище (рис. 1.3).



Рис. 1.3. Модель "елементу обробки"

Функція суматора може бути складнішою, наприклад, вибір мінімуму, максимуму, середнього арифметичного, добутку або обчислюватися за іншим алгоритмом. Багато програмних реалізацій використовують власні функції суматора, що запрограмовані на мові вищого рівня (C, C++ та ін.). Перед надходженням до передатної функції вхідні сигнали та вагові коефіцієнти можуть комбінуватись багатьма способами. Алгоритми для комбінування входів нейронів визначають відповідно до мережної архітектури та парадигми. В деяких нейромережах суматор виконує додаткову обробку, так звану функцію активації, яка зміщує вихід функції суматора в часі. Цю функцію найкраще використовувати як компоненту мережі в цілому, ніж як компоненту окремого нейрона. Часто, ця функція є відсутньою. Результат функції суматора перетворюється у вихідний сигнал через передатну функцію. В передатній функції для визначення виходу нейрона загальна сума порівнюється з деяким порогом (зазвичай, це діапазон $[0, 1]$ або $[-1, 1]$ або ін.) за допомогою певного алгоритму. Переважно застосовують нелінійну передатну функцію, оскільки лінійні (прямолінійні) функції є обмеженими і вихід є пропорційним до входу. Застосування лінійних передатних функцій було проблемою у ранніх моделях мереж, і їх обмеженість та недоцільність була доведена в книзі Мінскі та Пейпєрта

"Перцептрони". В існуючих нейромережах як передатну функцію використовують сигмоїду, синус, гіперболічний тангенс тощо.

Для простої передатної функції неймережа може видавати 0 чи 1, 1 чи -1 або інші числові комбінації. Передатна функція в таких випадках є пороговою або «жорстким обмежувачем» (рис. 1.4).




Рис. 1.4. Жорстка порогова функція

Передатна функція лінійна з насиченням (рис. 1.5) віддзеркалює вхід всередині заданого діапазону і діє як жорсткий обмежувач поза межами цього діапазону. Це лінійна функція, яка відсікається до мінімальних та максимальних значень, роблячи її нелінійною.




Рис. 1.5. Лінійна з насиченням

Сигмоїда або S-подібна крива наближує мінімальне та максимальне значення у асимптотах. Вона називається сигмоїдою (рис. 1.6), коли її діапазон $[0, 1]$, або гіперболічним тангенсом при діапазоні $[-1, 1]$. Важливою рисою сигмоїд є неперервність функцій та їх похідних. Застосування сигмоїдних функцій надає добрі результати і має широке застосування.




Рис. 1.6. Сигмоїда

Для різних нейромереж можуть вибиратись інші передатні функції. Після обробки сигналу, нейрон на виході має результат передатної функції, який надходить на входи інших нейронів або до зовнішнього з'єднання, як це передбачається структурою нейромережі.

1.2. Історія розвитку галузі штучних нейронних мереж

Нейронні мережі це не щось нове, вперше згадка датована ще 1943 року. Нейрофізіологом Ворреном Мак-Каллоком і логіком Волтером Піттсом, вдалося формалізувати поняття нейронних мереж у фундаментальній статті про логічне обчислення ідей і нервової активності, а також змодельували біологічну роботу органічного нейрона за допомогою електричних ланцюгів. У перекладі статті 1943 року Воррена Мак-Каллока і Волтера Піттса читаємо: “Через характер нервової діяльності «все або нічого», нейронні події та відносини між ними можна розглядати за допомогою пропозиційної логіки. Виявлено, що поведінка кожної мережі може бути описана цими термінами з додаванням більш складних логічних засобів для мереж, що містять кола; і що для будь-якого логічного виразу, який задовольняє певні умови, можна знайти мережу, яка поводить себе так, як вона описує. Показано, що багато конкретних варіантів серед можливих нейрофізіологічних припущень є еквівалентними в тому сенсі, що для кожної мережі, яка веде себе за одним припущенням, існує інша мережа, яка поводить себе по іншому і дає ті самі результати, хоча, можливо, не в той самий час. Обговорюються різні застосування числення”.

Але насправді можна також віднести першу згадку Вільгельма Ленца та Ернеста Ізінга, які створили та проаналізували модель Ізінга 1925 року, яка, по суті, є штучною рекурентною нейронною мережею без навчання, що складається з нейроноподібних порогових елементів, а у 1972 року Сун'їті Амарі зробив цю архітектуру адаптивною. Його навчання популяризував Джон Гопфілд 1982 року.

У 1949 році фізіолог Дональд Хебб написав книгу «Організація поведінки: нейропсихологічна теорія». У ній учений зазначив, що нервові шляхи посилюються при кожному наступному використанні, особливо між нейронами, схильними збуджуватися одночасно.

Робота Хебба стала початком довгого шляху до кількісної оцінки складних процесів, що відбуваються в мозку.

У 1958 році натхненний публікацією Маккаллоха і Піттса нейрофізіолог Френк Розенблатт розробив перцептрон. Саме його можна назвати першою практичною реалізацією нейромережі. А вже у 1960 році Френк Розенблатт розробив обчислювальну машину «Марк І» на базі перцептрона. Це була система з простим взаємозв'язком вхід-вихід, здатна навчатися в найпростіших завданнях. Але за рік до цього у 1959 році дослідники Стендфордського університету Бернард Відроу і Тед Хофф розробили першу нейронну мережу MADALINE, успішно застосовану до реальної проблеми.

Вона використовується досі і допомагає усувати перешкоди в телефонних лініях. Такі ранні дослідження в цій області породили широкий резонанс навколо того, щоб далі проводити дослідження в області нейронних мереж.

За увесь час дана область широко розвивалась. У 1961 році піонери штучного інтелекту Джером Візнер, Олівер Селфрідж і Клод Шеннон випустили телепередачу про те, що дана область є майбутнім світу. Але найбільший розголос стався вже у 80-ті, коли у 1982 році вчений Джон Гопфілд представив модель із двонаправленими зв'язками нейронів, відому

як нейромережа Гопфілда. Вона стала першим алгоритмом з асоціативною пам'яттю. У 1987 році Інститут інженерів електротехніки та електроніки організував першу Міжнародну конференцію з нейронних мереж. Згодом дана галузь почала все активніше розвиватися. А вперше простий користувач міг дізнатися про штучні нейронні мережі завдяки Google. Саме цей сервіс пошуку вперше запровадив програму, яка була здатна запам'ятовувати, аналізувати та відтворювати інформацію.

Що стосується сфер, де активно застосовують штучні нейронні мережі, то мабуть жодна аналітика не обходиться без застосування прогнозування за допомогою штучної нейронної мережі, що дає змогу спрогнозувати майбутню поведінку того чи іншого предмета галузі. Нейромережі лежать в основі також безлічі додатків і сервісів. Наприклад, їх використовує Apple для розуміння і генерації мови голосовим помічником Siri, а Microsoft – для перекладу веб-сторінок у реальному часі в браузері Bing.

У 2022 році почали набирати популярності алгоритми, що дають змогу всім охочим створювати унікальні картини за уривком тексту. ШІ-генератори зображень на кшталт DALL-E 2, Midjourney і Stable Diffusion XL досі мають попит і застосовуватимуться ще довгий час.

У 2023 році спільнота почала активно розробляти і застосовувати чат-боти, що базуються на великих мовних моделях. Технологія дає змогу користувачам поставити запитання, ввести запит або підказку й отримати розгорнуту «майже людську» текстову відповідь.

Чат-боти на кшталт ChatGPT від OpenAI здатні розмовляти на різноманітні теми та розуміти контекст, визнавати помилки, жартувати та сперечатися.

Крім цього, нейромережі використовують у різних галузях, зокрема:

- комп'ютерний зір для безпілотних автомобілів, дронів і роботів-доставщиків;
- ідентифікація облич у системах відеоспостереження;
- розпізнавання і синтез мови, а також мови для сервісних ботів;

- рекомендаційні системи в електронній комерції, музичних і відео-платформах, соціальних мережах;
- асистування лікарям у діагностуванні хвороб і складанні медичних нотаток клінічного обстеження пацієнтів;
- допомога фахівцям у пошуку нових лікарських сполук;
- можливість профілактичного обслуговування інфраструктури шляхом аналізу даних датчиків Інтернету речей і багато іншого.

Серед недоліків, можна виділити наступні: точність роботи нейромережі безпосередньо залежить від якості та кількості навчальних даних. Іноді створення високоефективних моделей вимагає величезних обсягів інформації.

1.3. Архітектура з'єднань штучних нейронних мереж та їх типи

За час розвитку ШНМ створено безліч архітектур з'єднань штучних нейронних мереж, а також типів нейронних мереж. З'єднання є важливою частиною, будь-якої мережі, оскільки дає змогу забезпечити передачу сигналів між іншими елементами. Раніше ми описували як передаються сигнали між біологічними нейронами, те саме робиться і з штучними нейронами, але за іншою схемою.

Штучні нейромережі конструюються з базового блоку – штучного нейрону. А самі вони задаються у вигляді направлених графів, де вершинами і є самі нейрони, а зв'язки, які існують між нейронами називаються ребрами, вони здатні взаємодіяти один з одним і передавати інформацію. Що стосується типів, видів і т.д, то нейромережі найчастіше поділяються на три категорії:

- мережі з повним набором міжнейронних зв'язків;
- мережі з фіксованим індексом оточення;
- мережі з пошаровою структурою.

Групування нейронів у мозку людини забезпечує обробку інформації динамічним, інтерактивним та самоорганізуючим шляхом. Біологічні нейронні мережі з мікроскопічних компонентів існують у тривимірному просторі і здатні до різноманітних з'єднань. Але для реалізації штучних мереж є фізичні обмеження. Об'єднуючись у мережі, штучні нейрони утворюють систему обробки інформації, яка забезпечує ефективну адаптацію моделі до постійних змін з боку зовнішнього середовища. В процесі функціонування мережі відбувається перетворення вхідного вектора сигналів у вихідний. Конкретний вид перетворення визначається архітектурою нейромережі, характеристиками нейронних елементів, засобами керування та синхронізації інформаційних потоків між нейронами. Важливим фактором ефективності мережі є встановлення оптимальної кількості нейронів та типів зв'язків між ними. Для опису нейромереж використовують кілька усталених термінів, які в різних джерелах можуть мати різне трактування, зокрема:

Структура нейромережі – спосіб зв'язків нейронів у нейромережі.

Архітектура нейромережі – структура нейромережі та типи нейронів.

Парадигма нейромережі – спосіб навчання та використання, іноді містить поняття архітектури.

Кожен із цих термінів несе свій сенс, у цьому є можливість структурованого використання мережі.

Якщо розглядати лише цей аспект структур нейромереж, то можна сказати, що структури з повним з'єднанням є узагальненими структурами, оскільки всі інші довільні об'єднання можуть розглядатися, як підмножини даної структури. Можна буде поступово переходити до самих структур, де бувають випадки, коли необхідно використовувати структури з великою кількістю нейронів. У випадку, коли необхідно використовувати структури з великою кількістю нейронів, застосовують кліткові структури з фіксованим індексом оточення. Ще однією важливою характеристикою нейронних мереж із постійним індексом оточення є модульність. Потужність структури у цьому випадку може нарощуватись простим додаванням елементів без зміни

ідеології алгоритму, що на ній працює. Щодо типів структур, то нейронні структури з повним з'єднанням можуть бути як одношаровими, так і багатошаровими.

У одношаровій структурі з повним з'єднанням всі вхідні сигнали можуть поступати на всі нейрони. Класичною структурою даного типу є персептрон Розенблатта.

Багатошарові мережі з повним з'єднанням забезпечують можливість передачі інформації з кожного нейрона попереднього шару на будь-який нейрон наступного. Найчастіше це – багатошарові персептрони.

На базі однієї архітектури може бути реалізовано різні парадигми нейромережі і навпаки. Серед відомих архітектурних рішень виділяють групу слабозв'язаних нейронних мереж (рис. 1.7), у випадку, коли кожен нейрон мережі зв'язаний лише із сусідніми. В повнозв'язаних нейромережах (рис. 1.8) входи кожного нейрона зв'язані з виходами всіх решти нейронів.




Рис. 1.7. Слабозв'язані нейромережі




Рис. 1.8. Повнозв'язані нейромережі

Самим поширеним варіантом архітектури є багатошарові мережі (рис. 1.9). Нейрони в даному випадку об'єднуються у прошарки з єдиним вектором вхідних сигналів. Зовнішній вхідний вектор подається на вхідний

прошарок нейронної мережі (рецептори). Виходами нейронної мережі є вихідні сигнали останнього прошарку (ефектори). Окрім вхідного та вихідного прошарків, нейромережа має один або кілька прихованих прошарків нейронів, які не мають контактів із зовнішнім середовищем.




Рис. 1.9. Багатошаровий тип з'єднання нейронів

Зв'язки між нейронами різних прошарків називають проєктивними. Зв'язки між нейронами одного прошарку називають бічними (латеральними). Хоча існують мережі, які містять лише один прошарок, або навіть один елемент, більшість застосувань вимагають мережі, які містять як мінімум три типи прошарків – вхідний, прихований та вихідний. Прошарок вхідних нейронів отримує дані або з вхідних файлів, або безпосередньо з електронних давачів. Вихідний прошарок пересилає інформацію безпосередньо до зовнішнього середовища, до вторинного комп'ютерного процесу, або до інших пристроїв. Між цими двома прошарками може бути багато прихованих прошарків, які містять багато нейронів в різноманітних зв'язаних структурах. Входи та виходи кожного з прихованих нейронів сполучені з іншими нейронами. Важливим аспектом нейромереж є напрямок зв'язку від одного нейрону до іншого. Зв'язки скеровані від вхідних прошарків до вихідних називаються аферентними. Зв'язки в зворотньому напрямку називаються еферентними. Під час проходження нейронного зв'язку у зворотньому напрямку, вихід нейронів скеровується до нейронів попереднього прошарку (рис. 1.10).




Рис. 1.10. Зворотній зв'язок

Напрямок зв'язків нейронів має значний вплив на роботу мережі. Більшість програмних нейромереж дозволяють користувачу додавати, вилучати та керувати з'єднаннями як завгодно. Корегуючи параметри, можна налаштувати зв'язки як на посилення, так і на послаблення величини сигналів. За архітектурою зв'язків, більшість відомих нейромереж можна згрупувати у два великі класи:

- мережі прямого поширення (з односкерованими послідовними зв'язками);
- мережі зворотного поширення (з рекурентними зв'язками).

Щодо архітектури, то вона поділяється на багато типів, існують прямого поширення мережі і рекурентного, фізичні, гібридні, мережі з пам'яттю і динамічні.

Нейронна мережа прямого поширення була першою, яку створили і вона почала активно використовуватися. У цій мережі інформація рухається лише від шару входу безпосередньо крізь будь-які приховані шари до шару виходу, без циклів/петель.

На даний момент існують 6 мереж *прямого поширення*.

Метод групового урахування аргументів

Метод групового урахування аргументів має повністю автоматичну структурну та параметричну оптимізацію моделі. Передавальними

функціями вузлів є поліноми Колмогорова – Габора, які допускають додавання та множення. Він використовує глибокий багат шаровий перцептрон із вісьмома шарами. Це мережа керованого навчання, яка зростає шар за шаром, де кожен шар тренується за допомогою регресійного аналізу. Розмір та глибина отримуваної мережі залежать від поставленого завдання.

Автокодувальник

Автокодувальник, автоасоціатор або мережа діаболо, схожий на багат шаровий перцептрон – із шаром входу, шаром виходу й одним або декількома прихованими шарами, що їх з'єднують. Автокодувальник використовують для некерованого навчання ефективних кодувань, зазвичай з метою зниження розмірності та для навчання породжувальних моделей даних.

Ймовірнісна нейронна мережа (ІНМ) – це чотирирівнева нейронна мережа прямого поширення. Шари: входу, приховані образів та підсумовування, та виходу. В алгоритмі ІНМ батьківську функцію густини ймовірності кожного класу наближують вікном Парцена та непараметричною функцією. Потім, використовуючи ФГІ кожного класу, оцінюють класову ймовірність нового входу та використовують правило Баєса, щоб віднести його до класу з найвищою апостеріорною ймовірністю.

Нейронна мережа з часовою затримкою – це архітектура прямого поширення для послідовних даних, яка розпізнає ознаки незалежно від положення в послідовності. Щоб досягти інваріантності щодо зсуву в часі, до даних входу додають затримки, щоб кілька точок даних (точок у часі) аналізувалися разом.

Згорткова нейронна мережа (ЗНМ) – це клас глибоких мереж, складених з одного або кількох згорткових шарів, із повноз'єднаними шарами (що відповідають шарам типових ШНМ). Вона використовує зв'язані ваги та шари агрегування. Зокрема, максимізаційного агрегування. Її часто структурують за допомогою згорткової архітектури Фукусіми. Вони є

видозмінами багат шарових перцептронів, які використовують мінімальну попередню обробку. Ця архітектура дозволяє ЗНМ використовувати переваги двовимірної структури даних входу.

Глибока складальна мережа (ГСМ) ґрунтується на ієрархії блоків спрощених нейромережних модулів. Її запропонували 2011 року Ден та Дон. Вона формулює навчання як задачу опуклої оптимізації з розв'язком замкненого вигляду, підкреслюючи подібність цього механізму до складального узагальнювання. Кожен блок ГСМ – це простий модуль, який сам по собі легко натренувати керованим чином без зворотного поширення для цілих блоків.

Рекурентні нейронні мережі (РНМ) поширюють дані вперед, але також і назад, від пізніших етапів обробки до попередніх. РНМ можливо використовувати як загальні обробники послідовностей.

- *Повнорекурентна*

Цю архітектуру розроблено в 1980-х роках. Її мережа створює орієнтоване з'єднання між кожною парою вузлів. Кожен має змінне в часі дійснозначне (більше ніж нуль чи одиниця) збудження (вихід). Кожне з'єднання має змінювану дійснозначну вагу. Деякі з вузлів називаються міченими вузлами, деякі – вузлами виходу, решта – прихованими вузлами.

- *Мережа Гопфілда*

Нейронна мережа Гопфілда – це тип рекурентної, повнозв'язної, штучної нейронної мережі з симетричною матрицею зв'язків. У процесі роботи динаміка таких мереж сходиться (конвергує) до одного з положень рівноваги. Ці положення рівноваги є локальними мінімумами функціоналу, що називається *енергія мережі* (у найпростішому випадку – локальними мінімумами негативно визначеної квадратичної форми на n -вимірному кубі). Така мережа може бути використана як автоасоціативна пам'ять, як фільтр, а також для розв'язання деяких завдань оптимізації. Схему мережі Гопфілда з трьома нейронами подано на рис. 1.11.




Рис. 1.11. Схема мережі Гопфілда з трьома нейронами

Нейронна мережа Гопфілда складається з штучних нейронів. Кожен нейрон системи може набувати одного з двох станів -1 або 1 (що аналогічно виходу нейрона з пороговою функцією активації).

- *Машина Больцмана*

Машина Больцмана – це стохастична модель спінового скла із зовнішнім полем, тобто модель Шеррінгтона – Кіркпатріка, що є стохастичною моделлю Ізінга. Це методика статистичної фізики, яку застосовують у контексті когнітивної науки. Її також класифікують як марковське випадкове поле. Машини Больцмана теоретично захоптиві через локальність і геббову природу їхнього алгоритму тренування (тренуються за геббовим правилом), а також через їхню паралельність і подібність їхньої динаміки до простих фізичних процесів. Машини Больцмана з необмеженою зв'язністю не виявилися корисними для практичних задач у машинному навчанні та висновуванні, але якщо зв'язність належним чином обмежено, то навчання можливо зробити достатньо ефективним, щоб воно було корисним для практичних задач (рис. 1.12).




Рис. 1.12. Графове подання прикладу машини Больцмана

- Самоорганізаційна карта Кохонена

Самоорганізаційна карта Кохонена – нейронна мережа з некерованим навчанням, яка використовується для конструювання багатовимірного простору в простір з нижчою розмірністю (найчастіше, двовимірний). Створює дискретне представлення вхідних просторів навчальних вибірок, які називаються картою, і тому використання цього типу нейронної мережі є методом для зниження розмірності. Самоорганізовані карти відрізняються від інших штучних нейронних мереж, оскільки вони застосовують конкурентне навчання, яке є протилежним до навчання з виправленням помилок, і в тому сенсі, що вони використовують функцію сусідства для збереження топологічних властивостей вхідного простору.

Це робить самоорганізовані карти корисними для візуалізації шляхом створення маловимірних зображень багатовимірних даних, цей процес схожий на багатовимірне шкалювання. Штучну нейронну мережу, впроваджену фінським професором Теуво Кохоненом у 1980-х роках, іноді називають картою Кохонена або мережею Кохонена.

– Стохастична нейронна мережа

Стохастичні нейронні мережі, що походять від моделей Шеррінгтона – Кіркпатріка, це один з типів штучних нейронних мереж, побудований шляхом введення випадкових варіацій у мережу, або надаванням штучним нейронам мережі стохастичних передавальних функцій, або надаванням їм

стохастичних ваг. Це робить їх корисними інструментами для розв'язування задач оптимізації, оскільки випадкові флуктуації допомагають мережі уникати локальних мінімумів. Стохастичні нейронні мережі, треновані за допомогою баєсового підходу, відомі як баєсові нейронні мережі.

– *Двонаправлена рекурентна нейронна мережа*

У двонаправленій рекурентній нейронній мережі (скорочено англ. мовою BRNN) (рис. 1.13) з'єднують у протилежних напрямках два прихованих шари з однаковим входом. Завдяки такій формі породжувального навчання, вихідний шар рекурентної нейронної мережі може отримувати інформацію з минулих (попередніх) та майбутніх станів (наступних) одночасно. Вони були винайдені в 1997 році Майком Шустером і Кулдіпом Палівалем. BRNN були введені для збільшення кількості вхідної інформації, доступної для мережі. BRNN особливо корисні, коли наявність контексту вхідних даних покращує результат. Наприклад, при розпізнаванні рукописного тексту, точність може бути посилена розпізнаванням букв, розташованих до і після поточної.




Рис. 1.13. Структура двонаправленої нейронної мережі

Сама архітектура BRNN є недосить складною і легка для навчання, тому й широко застосовується в методах прогнозування. Принцип BRNN полягає в тому, щоб розбити нейрони звичайної RNN на два напрямки: один для додатного напрямку часу (подальші стани), а інший для від'ємного

напрямку часу (попередні стани). Вихід цих двох станів не пов'язаний з входами станів протилежного напрямку.

- **Довга короткочасна пам'ять**

Довга короткочасна пам'ять (ДКЧП), англійською мовою розшифровується як *long short-term memory*, скорочено *LSTM* – це архітектура рекурентних нейронних мереж (РНМ, штучна нейронна мережа), запропонована 1997 року Зеппом Хохрайтером та Юргеном Шмідгубером. Як і більшість РНМ, мережа ДКЧП є універсальною в тому сенсі, що за достатньої кількості вузлів мережі вона може обчислювати будь-що, що може обчислювати звичайний комп'ютер, за умови, що вона має належну матрицю вагових коефіцієнтів, що може розглядатися як її програма. На відміну від традиційних РНМ, мережа ДКЧП добре підходить для навчання з досвіду з метою класифікації, обробки або передбачення часових рядів в умовах, коли між важливими подіями існують часові затримки невідомої тривалості.

Що стосується архітектури, то вона виглядає наступним чином і продемонструємо це на прикладі блок вічкової ДКЧП (рис. 1.14):




Рис. 1.14. Блок вічкова ДКЧП з входним, виходним та забувальним вентилями

Що стосується опису архітектури ДКЧП, то вона є досить складною для навчання. Мережа ДКЧП є штучною нейронною мережею, яка містить вузли ДКЧП замість, або на додачу, до інших вузлів мережі. Вузол ДКЧП – це вузол рекурентної нейронної мережі, який виділяється запам'ятовуванням значень для довгих або коротких проміжків часу.

Розглянемо динамічні нейронні мережі.

Динамічні нейронні мережі розглядають нелінійну багатовимірну поведінку та включають (навчання) залежної від часу поведінки, такої як перехідні явища та ефекти затримки. Методики оцінювання системного процесу на основі спостережуваних даних підпадають під загальну категорію виявлення системи. Вони також діляться на види. На даний момент існує 3 види динамічних нейромереж: каскадна, нейронечітка, композиційна шаблонотворювальна. Кожен вид по-своєму унікальний і має певні властивості.

Дамо їх коротку характеристику.

Каскадна кореляція – це архітектура та алгоритм керованого навчання. Замість простого підлаштування ваг у мережі з фіксованою топологією, каскадна кореляція починається з мінімальної мережі, а потім автоматично тренується та додає нові приховані вузли один за одним, створюючи багат шарову структуру. Щойно новий прихований вузол додано до мережі, його ваги з боку входу заморожуються. Архітектура каскадної кореляції має кілька переваг: вона швидко навчається, визначає власний розмір і топологію, зберігає створені структури, навіть якщо тренувальний набір змінюється, і не вимагає зворотного поширення.

Нейронечітка мережа – це система нечіткого висновування в тілі штучної нейронної мережі. Залежно від типу СНВ кілька шарів імітують процеси, залучені у подібних до нечіткого висновування – внесенні нечіткості, висновуванні, агрегуванні та відновленні чіткості. Вбудовування СНВ у загальну структуру ШНМ має перевагу використання доступних методів тренування ШНМ для знаходження параметрів нечіткої системи.

Композиційні шаблонотворювальні мережі – це різновид штучних нейронних мереж, які відрізняються своїм набором передавальних функцій та способом їх застосування. У той час як типові штучні нейронні мережі часто містять лише сигмоїдні функції (іноді гаусові), КШСМ можуть містити обидва типи функцій та багато інших. Крім того, на відміну від типових

штучних нейронних мереж, КШСМ застосовують над усім простором можливих даних входу, щоб вони могли подавати повне зображення.

Щодо інших типів, то до них належать: миттєво треновані, спайкові, просторові, неокогнітрон, змішані ієрархічно-глибокі мережі.

- *Миттєво треновані*

Миттєво треновані нейронні мережі були натхнені явищем короткочасного навчання, яке, здається, відбувається миттєво. У цих мережах ваги прихованого шару та шару виходу відображаються безпосередньо з даних тренувального вектора. Зазвичай вони працюють з двійковими даними, але існують версії й для неперервних даних, які потребують невеликої додаткової обробки.

- *Спайкові*

Спайкові нейронні мережі явно враховують хронометраж вхідних даних. Вхід та вихід цієї мережі зазвичай подано у вигляді рядів спайків (дельта-функції або складнішого вигляду). СНМ може обробляти інформацію в часовій області (сигналів, які змінюються в часі). Їх часто втілюють як рекурентні мережі. СНМ також є одним із видів імпульсних комп'ютерів.

Спайкові нейронні мережі з затримками аксональної провідності демонструють поліхронізацію, і відтак можуть мати дуже велику ємність пам'яті. СНМ та часові кореляції нейронних збірок у таких мережах використовували для моделювання поділу фігур/тла та з'єднання областей у зоровій системі.

- *Просторові*

Просторові нейронні мережі становлять надкатегорію спеціалізованих нейронних мереж (НМ) для подавання та передбачування географічних явищ. Вони загалом покращують як статистичну точність, так і надійність просторових/класичних НМ, коли обробляють геопросторові набори даних, а також інших просторових (статистичних) моделей (наприклад, просторових регресійних моделей), коли змінні цих геопросторових наборів даних

описують нелінійні зв'язки. Прикладами ПНМ є просторові нейронні мережі *OSFA*, *SVANN* та *GWNN*.

- *Неокогнітрон*

Неокогнітрон – це ієрархічна багатошарова мережа, змодельована на основі зорової кори. Він використовує кілька типів вузлів, та складними як каскадну модель для використання в задачах розпізнавання образів. Локальні ознаки виділяють *S*-клітини, деформацію яких допускають *C*-клітини. Локальні ознаки у вході поступово інтегруються та класифікуються на вищих шарах. Серед різних видів неокогнітронів є системи, які можуть виявляти декілька образів в одному вході за допомогою зворотного поширення для досягнення вибіркової уваги.

За підсумком розглянутого, подамо загальну характеристику штучних нейронних мереж у вигляді схеми (рис. 1.15).

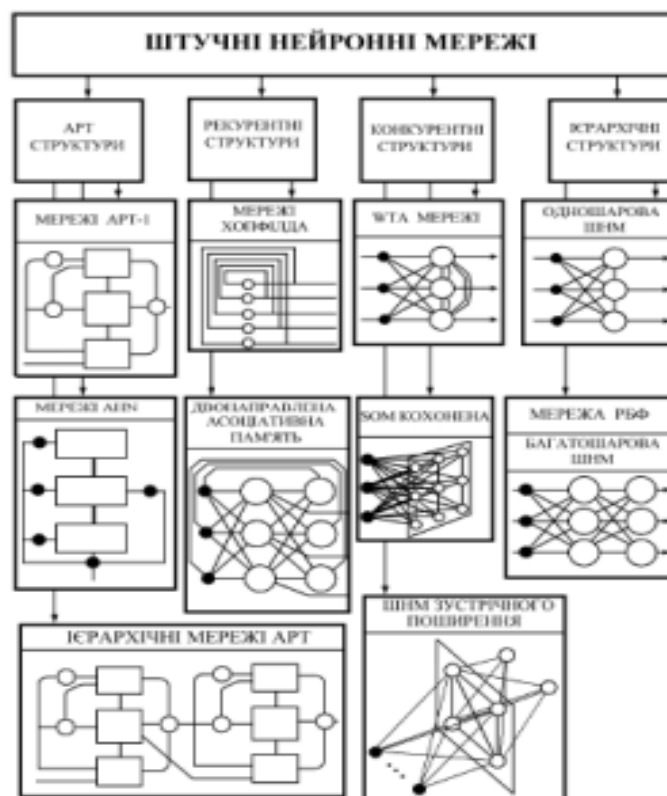


Рис. 1.15. Загальна характеристика штучних нейронних мереж та їх видів

1.4. Навчання штучних нейронних мереж

Навчання – це пристосовування мережі для кращого виконання завдання шляхом розгляду вибіркового спостереження. Навчання включає підлаштування ваг (і, можливо, порогів) мережі для підвищення точності результатів. Це здійснюється шляхом мінімізування спостережуваних похибок. Навчання завершено, якщо розгляд додаткових спостережень не знижує рівня похибки. Навіть після навчання рівень похибки зазвичай не досягає 0. Якщо навіть після навчання рівень похибки занадто високий, зазвичай потрібно змінити будову мережі. Практично це здійснюють шляхом визначення функції витрат, яку періодично оцінюють протягом навчання. Поки її результат знижується, навчання триває. Витрати часто визначають як статистику, значення якої можливо лише наближувати. Виходи насправді є числами, тож коли похибка низька, різниця між результатом і правильною відповіддю невелика. Навчання намагається знизити загальну відмінність над спостереженнями. Більшість моделей навчання можна розглядати як пряме застосування теорії оптимізації та статистичного оцінювання. Отже ми можемо сказати, що навчання є дуже важливим для більшої оптимізації створюваної нейромережі. Але важливими є критерії за якими здійснюють навчання. Серед основних це: **темп навчання, функція витрат, зворотне поширення**. Розглянемо детальніше кожний критерій.

- **Темп навчання**

Темп навчання визначає розмір коригувальних кроків, які здійснює модель для підлаштування під похибку в кожному спостереженні. Високий темп навчання скорочує тривалість тренування, але з меншою кінцевою точністю, тоді як нижчий темп навчання займає більше часу, але з потенціалом до більшої точності. Такі оптимізації, як швидкопоширювальні, переважно спрямовані на прискорення мінімізування похибки, тоді як інші вдосконалення переважно намагаються підвищити надійність. Адаптивний темп навчання спрямований на те, щоб запобігти циклічним коливанням

усередині мережі, таким як чергування ваг з'єднань, і покращити швидкість збігання, удосконалення, який підвищується або знижується належним чином.

- **Функція витрат**

Хоча й можливо визначати функцію витрат, вибір часто визначається бажаними властивостями цієї функції, такими як опуклість або тим, що вона постає з моделі, наприклад, у ймовірнісній моделі апостеріорну, що являє собою умовну ймовірність, котра присвоюється після урахування відповідного свідчення або вихідних даних, або простіше кажучи розподіл невідомої величини, яку розглядають як випадкову змінну, ймовірність моделі здатна використовувати як обернені витрати. Можемо сказати, що для того щоб віднайти функції витрат потрібно враховувати безліч параметрів, що дозволить ефективно віднайти результат.

- **Зворотнє поширення помилки**

Метод зворотнього поширення помилки – метод навчання багат шарового перцептронну. Це ітеративний градієнтний алгоритм, який використовується з метою мінімізації помилки роботи багат шарового перцептронну та отримання бажаного виходу. Основна ідея цього методу полягає в поширенні сигналів помилки від виходів мережі до її входів, в напрямку, зворотному прямому поширенню сигналів у звичайному режимі роботи. Барц і Охонін запропонували відразу загальний метод («принцип подвійності»), який можна застосувати до ширшого класу систем, включаючи системи з запізненням, розподілені системи, тощо. Для можливості застосування методу зворотнього поширення помилки функція активації нейронів повинна бути диференційовною.

Щодо критеріїв, то вони і є основні, а щодо методів навчання то вони є такі: *контрольоване навчання і неконтрольоване.*

- **Контрольоване навчання**

Більшість реалізацій нейромереж використовують контрольоване навчання, де вихід, що змінюється, постійно порівнюється з бажаним

виходом. Вагові коефіцієнти зв'язків на початку встановлюються випадково (ініціалізація мережі), але під час наступних ітерацій корегуються, щоб досягти близької відповідності між бажаним та біжучим виходами. Такі методи навчання націлені на мінімізацію біжучих похибок всіх елементів обробки, що відбувається завдяки неперервній зміні синаптичних ваг до досягнення прийнятної точності мережі. Перед використанням, нейромережа з контрольованим навчанням повинна бути навченою. Фаза навчання займає певний час. Навчання вважається закінченим при досягненні нейромережею визначеного користувачем рівня ефективності і бажаної статистичної точності. Після навчання вагові коефіцієнти зв'язків фіксуються для подальшого застосування. Деякі типи мереж дозволяють під час використання продовжувати навчання, і це допомагає мережі адаптуватись до змінних умов. Навчальні множини повинні бути достатньо великими, щоб містити всю необхідну інформацію для виявлення важливих особливостей і зв'язків. Навчальні приклади повинні містити широке різноманіття даних. Якщо мережа навчається лише для одного прикладу, вагові коефіцієнти, що старанно встановлено для цього прикладу, радикально змінюються у навчанні для наступного прикладу. Попередні приклади при навчанні наступних просто забуваються. В результаті система повинна навчатись всьому разом, знаходячи найкращі вагові коефіцієнти для загальної множини прикладів. Наприклад, у навчанні системи розпізнавання піксельних образів для десяти цифр, які представлені двадцятьма прикладами кожної цифри, всі приклади цифри "сім" не доцільно представляти послідовно. Краще надати мережі спочатку один тип представлення всіх цифр, потім другий тип і так далі. Головною компонентою для успішної роботи мережі є представлення і кодування вхідних і вихідних даних. Штучні мережі працюють лише з числовими вхідними даними, отже, необроблені дані, що надходять із зовнішнього середовища повинні перетворюватись. Важливою є нормалізація даних, тобто приведення всіх значень даних до єдиного діапазону. Нормалізація виконується шляхом ділення кожної компоненти вхідного

вектора на довжину вектора, що перетворює вхідний вектор в одиничний. Попередня обробка зовнішніх даних, отриманих за допомогою сенсорів, у машинний формат є спільною і легко доступною для стандартних комп'ютерів. Якщо після контрольованого навчання нейромережа ефективно опрацьовує дані навчальної множини, важливим стає її ефективність при роботі з даними, які не використовувались для навчання. У випадку отримання незадовільних результатів для тестової множини, навчання продовжується. Тестування використовується для забезпечення запам'ятовування не лише даних заданої навчальної множини, але і створення загальних образів, що можуть міститись в даних.

- *Неконтрольоване навчання*

Неконтрольоване навчання може бути великим надбанням у майбутньому. Воно проголошує, що комп'ютери можуть самонавчатись у справжньому роботизованому сенсі. На даний час, неконтрольоване навчання використовується в мережах відомих, як самоорганізовані карти (self organizing maps). Мережі не використовують зовнішніх впливів для корегування своїх ваг і внутрішньо контролюють свою ефективність, шукаючи регулярність або тенденції у вхідних сигналах та здійснюють адаптацію відповідно до навчальної функції. Навіть без повідомлення правильності чи неправильності дій, мережа повинна мати інформацію відносно власної організації, яка закладена у топологію мережі та навчальні правила. Алгоритм неконтрольованого навчання скеровано на знаходження близькості між групами нейронів, які працюють разом. Якщо зовнішній сигнал активує будь-який вузол в групі нейронів, дія всієї групи в цілому збільшується. Аналогічно, якщо зовнішній сигнал в групі зменшується, це приводить до гальмуючого ефекту на всю групу.

Щодо оцінки навчання нейромережі, то вона залежить від кількох керованих факторів, важливими з яких є: *ємність, складність зразків і обчислювальна складність.*

Ємність показує, скільки зразків може запам'ятати мережа, і які межі прийняття рішень можуть бути на ній сформовані.

Складність зразків визначає кількість навчальних прикладів, необхідних для досягнення здатності мережі до узагальнення.

Обчислювальна складність напряму пов'язана з потужністю комп'ютера.

Висновки до розділу 1

Отже, штучні нейронні мережі – це математичні моделі, а також їх програмні або апаратні реалізації, побудовані за принципом організації й функціонування біологічних нейронних мереж, які у свою чергу при побудові використовують теорії математичного аналізу та моделювання, а також біологічну схему нейрона.

Також нейромережі мають доволі різноманітну і складну структуру поділу. Існує безліч видів нейронних мереж, зокрема їх підвидів. Кожен із них дає різноманітний спектр для дослідження і прогнозування, що доволі спрощує роботу аналітикам, які можуть обрати для своєї задачі свій тип нейронної мережі. Але, попри все ми можемо виділити загальну схему штучного нейрону, а саме: є вхідні сигнали, проміжний бар'єр, вихідний сигнал.

РОЗДІЛ 2. ДОСЛІДЖЕННЯ ЗАДАЧ ПРОГНОЗУВАННЯ ЗА ДОПОМОГОЮ ШТУЧНИХ НЕЙРОННИХ МЕРЕЖ

За час існування ШНМ налічується багато робіт із прогнозування штучних нейронних мереж, які допомогли тій чи іншій сфері розвинутися і стати ще більш ефективнішою. Зокрема серед проведених досліджень знайдено дуже багато корисних прогнозів. Перейдемо до наступного огляду задач і їх опису.

Перша задача стосується області кредитування, що широко використовується в банківській сфері. Дана область має величезний потенціал для сприяння економічному зростанню світової економіки і може бути цінним інструментом для підвищення фінансової інклюзії та ефективності, оскільки широко використовується в повсякденному житті як простими користувачами, так і різними установами. Але ми усі прекрасно розуміємо, що запорукою успіху не лише банківської сфери, а й будь-якого бізнесу, зокрема сюди входять і такі суб'єкти господарювання як: постачальники, інвестори, замовники і так далі, є правильна оцінка потенційних ділових партнерів, в цей перелік входить їх кредитоспроможність, а вона у свою чергу вимірюється кредитним рейтингом, які проводять аналітичні агентства. Але послуги цих агентств є доволі недешевими і лише підприємства з більш-менш потужним бюджетом можуть собі це дозволити.

Що стосується сфери економіки, то корпорації можуть діагностувати свій поточний стан фінансових справ на основні моделей прогнозування та визначити свої стратегії для подальшого майбутнього. Керівники в цьому плані після проведення аналізу зможуть здійснювати управління своїм бізнесом більш стабільно знаючи наперед усі ризики і у разі виникнення розуміти як їх вирішити. А замовники знатимуть наперед ціни по закупівлях та розумітимуть як ефективно і вигідно здійснювати товарообіг. Інвестори

переглядатимуть свої стратегії для ефективного формулювання свого інвестиційного портфелю.

Для цього і використовується кредитна оцінка спроможності компаній та окремих суб'єктів, що являє собою рейтинг облігацій, зосереджений на їхній потенційній здатності погашати корпоративні та державні облігації. Вони у свою чергу використовують її для оцінки своїх інвестицій і банківської спроможності.

Розглянемо дослідження Бородіна О.І. [2], 2022 р.

Для того щоб успішно прогнозувати, потрібний великий обсяг вхідних даних, включаючи фінансові коефіцієнти та усю інформацію про дефолти підприємства. Але великий нюанс є в тому, що ці дані кластеризуються по галузям, у яких працюють компанії різного спектру впливу, а сама динаміка варіюється від одного сектора економіки до іншого. Усі дані для того, щоб спрогнозувати можливість даної вибірки, знаходяться у фінансовій звітності компанії. Для створення нейромережі обираються навчальні, перевірочні, тестові дані. Після того, як дані занесені у вхідні, то здійснюється прогнозування. Нижче наведено структуру самої нейромережі (рис. 2.1).




Рис. 2.1. Схема нейромережі

У даній структурі вхідні дані подаються до першого шару нейронів, які обчислюють їх лінійні комбінації, а потім передають вихід через функцію активації до наступного шару. З рис. 2.2. можна побачити, як саме працює нейромережа на навчальній і тестовій вибірках [2].




Рис. 2.2. Навчання мережі: функції втрат на навчальній і тестовій вибірках

Як ми можемо помітити навчання перестає відбуватися тоді коли досягається стабільність, а вона у свою чергу починається від 100 епох і йде до 450 епох. Епоха – це період проведення навчання, який задається автоматично для проведення аналізу.

Але як і будь-яка мережа, ми можемо припуститися помилок, які можуть впливати на хід виконання результату, тому для цього проводять вибірку розрахунку відсотка помилок. Але перед тим, потрібно було розділити кредитний рейтинг компаній, які беруть участь у прогнозуванні на класи. Провівши дослідження було прийнято рішення розділити на такі класи: AAA, AA, A, CC, C, D. А після того вже можна було проводити оцінку помилок. На рис. 2.3. наведено матрицю помилок на тестовій вибірці.



Рис. 2.3. Нормалізована матриця помилок на тестовій вибірці

Із цієї матриці тестової вибірки, можна помітити, що середньоквадратична помилка становить 0,63 (63%), при активах 72,98% і 98,8 %, а вже після цього зможемо сформулювати таблицю кредитного скорингу [2].

Таблиця 2.1

Оцінка точності моделі для різних класів пропущених даних

	Активи	Довгострокові борги	Кредити
Accuracy 0	71.05%	62.5%	79.2%
Accuracy 1	98.5%	100%	99.65%
RMSE	0.72	0.83	0.59

А в кінці можемо навести сам прогноз, а точніше розподіл записів кредитного рейтингу (рис. 2.4) [2].

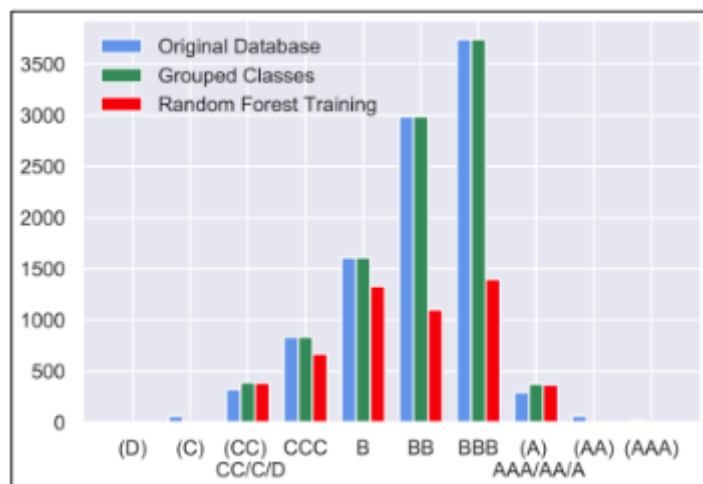


Рис. 2.4. Розподіл записів по класах кредитного рейтингу

Наступною задачею, яку ми будемо розглядати, як дослідження – задача прогнозування дохідності цінних паперів на підґрунті застосування інструментарію нейронних мереж [4].

Щоб перейти до розглядання задачі, нам потрібно з'ясувати у чому суть проблеми. На даний момент сфера покупки і продажів цінних паперів набирає обертів. І постає нагальне питання в ефективному прогнозі вартості цінних паперів в майбутньому. Тому дана проблема активно знайшла вирішення в питанні прогнозування нейромереж.

Для навчальної вибірки обрано 30 елементів, з яких 20 – будуть використовуватися для тренінгу (навчання), 5 – тестування та 5 – для повторного тестування [4].

Таблиця 2.2

Вхідні дані для навчання і тестування нейронної мережі

№ з/п	Дата	Значення котирувань, Ct	Різниця котирувань, ΔCt	Вид даних
	30. 08. 2010	0,5657		
1	31. 08. 2010	0,5623	-0,0034	Дані для навчання
2	01. 09. 2010	0,564	0,0017	
3	02. 09. 2010	0,5652	0,0012	
4	03. 09. 2010	0,5633	-0,0019	
5	06. 09. 2010	0,5664	0,0031	
6	07. 09. 2010	0,5679	0,0015	
7	08. 09. 2010	0,5681	0,0002	
8	09. 09. 2010	0,5731	0,005	
9	10. 09. 2010	0,5709	-0,0022	
10	13. 09. 2010	0,5712	0,0003	
11	14. 09. 2010	0,5717	0,0005	
12	15. 09. 2010	0,5652	-0,0065	
13	16. 09. 2010	0,5617	-0,0035	
14	17. 09. 2010	0,5709	0,0092	
15	20. 09. 2010	0,5702	-0,0007	
16	21. 09. 2010	0,5747	0,0045	
17	22. 09. 2010	0,5798	0,0051	
18	23. 09. 2010	0,5712	-0,0086	
19	24. 09. 2010	0,5705	-0,0007	
20	27. 09. 2010	0,5713	0,0008	

21	28. 09. 2010	0,5732	0,0019	Дані для тестування
22	29. 09. 2010	0,5793	0,0061	
23	30. 09. 2010	0,5676	-0,0117	
24	01. 10. 2010	0,5653	-0,0023	
25	04. 10. 2010	0,5562	-0,0091	
26	05. 10. 2010	0,5425	-0,0137	Дані для повторного тестування
27	06. 10. 2010	0,5521	0,0096	
28	07. 10. 2010	0,5537	0,0016	
29	08. 10. 2010	0,5478	-0,0059	
30	11. 10. 2010	0,5482	0,0004	

Нижче наведено побудову нейронної мережі у середовищі MATLAB. Після проведення багатьох експериментів було обрано нейронну мережу з прямим поширенням сигналу та зворотнім поширенням помилки. Схему представлено на рисунку 2.5 [4].

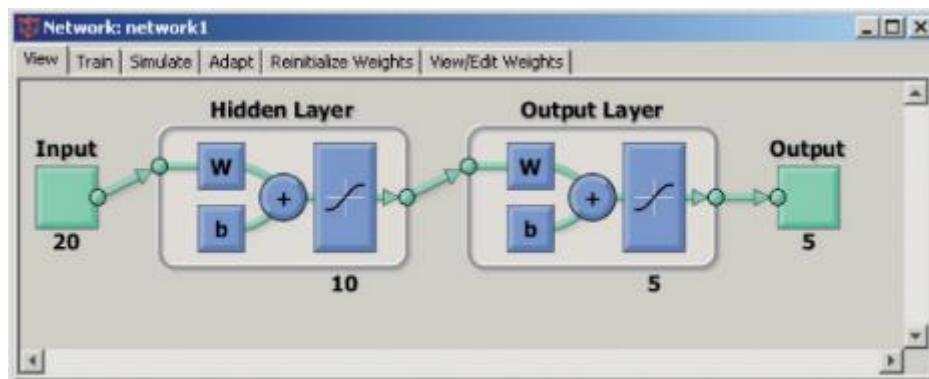


Рис. 2.5. Структура нейронної мережі

При проведенні досліджень було визначено найбільш точний прогноз, що отримуємо, якщо подавати дані у кількості, що є кратною 5. Кожному цьому моменту є своє логічне пояснення, основним це є залежність від дня коли проводяться торги, оскільки міжнародними агенціями встановлено, що на тиждень торги проводяться 5 днів (понеділок, вівторок, серeda, четвер, п'ятниця). Навчання здійснювали циклами (епохами). Що стосується прогнозувань, то воно проводилося у тестовому режимі. На рисунку 2.6. наведено результати навчання нейронної мережі [4].

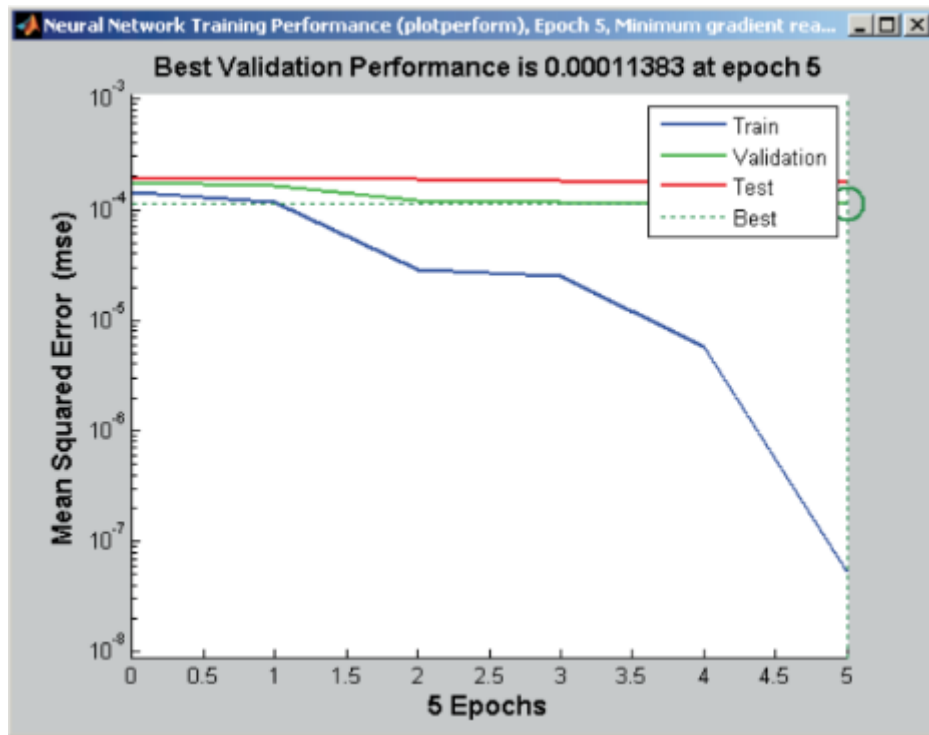


Рис. 2.6. Результати навчання нейронної мережі

На цій діаграмі ми можемо побачити, що цінні папери даної компанії мають стабільну ціну і не мають такого шаленого розриву на ринку котирування акцій. А з часом і будуть рости у ціні.

Дослідження проводилося для компанії ВАТ “Укртелеком” і було отримано прогноз, який доволі точний, вдалося описати дохідність цінних паперів компанії [4].

Третю задачу, яку ми розглянемо буде задача прогнозування страхового випадку за допомогою нейронних мереж, оскільки сфера страхування є доволі популярною у наш час, бо зараз на теперішній момент цими послугами користуються не лише люди, але й компанії. В основному страхують майно, а це зокрема автомобілі, квартири і так далі, а корпорації страхують в основному свій бізнес від втрат. Саме ризик і став тим наріжним каменем виникнення страхової компанії, мінімізує ці втрати від ризику, а вони у свою чергу і працюють у цій сфері ризику. Для покращення ефективності і розробляють методи боротьби і уникання ризиків, що дають змогу уникнути матеріальних втрат.

Щоб прогнозувати страховий випадок за допомогою штучних нейронних мереж, були взяті роботи таких учених, як: І.Г. Аберніхіна, І.Г. Сокиринська, Т.А.Говорушко, В.М. Стецюк, Н.І. Демчук, Л.В. Шірінян, П.В. Бондаренко, М.Д. Балджи, В.А. Карпов, А.І. Ковальов, О.О. Костусев, І.М. Котова, Н.В. Сметина, А.Н. Горбань.

Вони у своїх працях описували ринкову економіку та її ризики та розуміння відхилень їх загальновідомої норми. Вони у свою чергу передбачали дотримання наступних принципів, а саме: принцип участі, принцип безперервності, принцип обмеженості. Отож перед тим, як спрогнозувати нейронну мережу, ми підсумуємо, що головним завданням управління ризиками є забезпечення успішного функціонування фірми в умовах ризику і невизначеності [6].

Сама нейронна мережа написана на мові програмування Python TensorFlow, а вона у свою чергу складається з вхідного шару, чотирьох прихованих шарів та вихідного шару. Структуру мережі наведено на рисунку 2.7 [6].




Рис. 2.7. Структура нейронної мережі

Навчання проводиться на тестовій версії нейронної мережі, беручи за основу такі параметри, як мінімальні і максимальні входи та інші. Графік навчання нейронної мережі наведено на рисунку 2.8 [6].

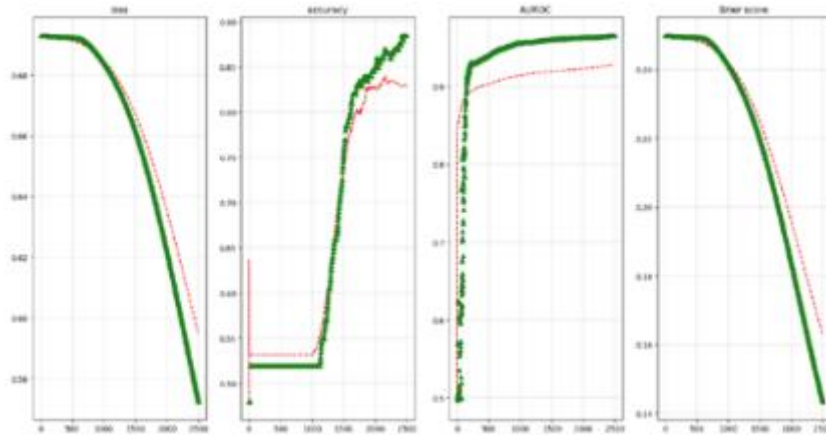


Рис. 2.8. Графік навчання нейронної мережі

З дослідження можемо побачити, що графіки коливаються і є нестабільними, оскільки йдуть догори і донизу. Результуючий графік подано на рис. 2.9 [6].

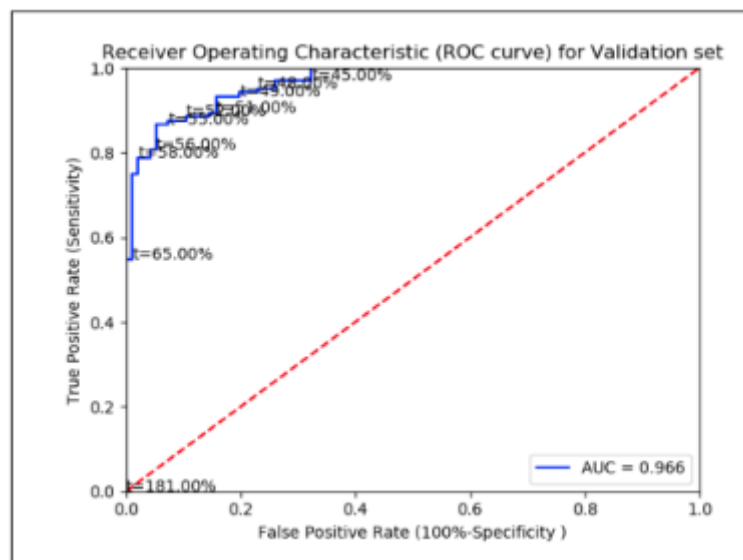


Рис. 2.9. Результуючий графік AUROC

Четверта задача прогнозування – **задача прогнозування споживання енергоресурсів.**

Енергоефективність – це властивість обладнання, технології, виробництва або систем взагалі, яка характеризує міру ефективності використання енергії на одиницю кінцевого продукту. Проблема підвищення енергоефективності, стала нагальною проблемою, оскільки вона дуже тісно пов'язана з прогнозуванням споживання енергоресурсів, яке завжди має бути

своєчасним і надійним. А також даний прогноз можна використати для передбачення нових ситуацій та проблем, які можна використати для подальшого розвитку в енергетичній сфері. Що стосується прогнозу, то він здійснюється за даними минулих періодів, а потім здійснюється порівняння з фактичними даними.

На сьогоднішній день сфера прогнозування енергоефективності стає все більш затребуваною і потребує контролю та системного прогнозування і опрацювання даних, але на сьогоднішній день залучення експертів із прогнозування коштує доволі немалої суми грошей, але результат окупить усі витрати.

Для того щоб ефективно отримати результати, спочатку потрібно побудувати архітектуру нейронної мережі, що стосується навчання, то їх види були описані вище, а у даному дослідженні було взято систему навчання, що містить взаємозв'язки, які у свою чергу знаходяться у навчальних даних на кожній ітерації. А після того, шляхом експериментів, було обрано архітектуру прямого поширення, вона наведена нижче на рис. 2.10 [5].




Рис. 2.10. Повнозв'язна нейронна мережа прямого поширення для вирішення задач прогнозування

Із даної схеми нейронної мережі, можемо бачити, що для дослідження було взято 5 днів і на вхід йшли дані саме цих попередніх п'ятих днів. Після цього було взято, які дані записувались у два блоки прихованих шарів у

кількості 7 одиниць на кожен блок. Після того потрібно було розрахувати зсув значень за днями, що і було зроблено у підсумку.

Навчати дану нейронну мережу можна, як з вчителем, так і неперервно, в підсумку було прийнято рішення навчати неперервно. Після завершення навчання із вчителем почали відображатися статистичні структури середовища, які з цього моменту вважають незмінними.

Але перед тим, як отримати значення потрібно було нормалізувати значення, яке перевищує процес навчання самої системи. Нормалізація здійснюється за формулою:

$$X_i = (X_1 - X_{\min}) / (X_{\max} - X_{\min}),$$

де : X_i – значення і-показника;

X_1 – значення 1-показника;

X_{\min} – значення мінімального показника;

X_{\max} – значення максимального показника;

В підсумку, здійснивши усі обчислення, отримали дані, які наведені у таблиці 2.3 [5].

Таблиця 2.3

Приклад нормалізованих даних

Параметр	Значення показника	Нормалізоване значення
День 1	60	0,0171
День 2	1	0,0003
День 3	1,8	0,0005
День 4	75	0,0214
День 5	28	0,0893

Дані в межах від 0 до 1 і можна з них побудувати сигмоїдальну функцію для системи нейронної мережі, але за зворотною формулою (рис. 2.11) [5].




Рис. 2.11. Сигмоїдальна функція для системи прогнозування на основі нейронної мережі

Після цього вже детально вимальовується модель нейрона для системи прогнозування, а отже маємо 5 даних на вхід, після чого всі дані обраховуються і за допомогою суматора, здійснюється обчислення суми, а вже потім значення суматора переходить до функції активації і в підсумку отримуємо вихідний сигнал. Усі ваги нейрона зберігаються в оперативній пам'яті. Отримавши чітке завдання ми зможемо сформулювати вже чітку архітектуру нейронної мережі [5].

Розв'язували задачу шляхом написання програмного комплексу на мові С#, враховуючи те що бралися короткострокові прогнози, до прикладу за 5 днів, то і звісно писалася програма для мережі прямого поширення.

На рис. 2.12. ми можемо побачити дані отримані за показами лічильника [5].




Рис. 2.12. Дані отримані за показами лічильника електроенергії

Дані отримані за допомогою прогнозування нейронних мереж подано на рисунку 2.13 [5].




Рис. 2.13. Дані, отримані способом прогнозування нейронною мережею

Як ми можемо побачити, то дані, які отримані за показами лічильників та дані за способом прогнозування відрізняються, зокрема можна побачити, що перші дні відрізняються один від одного, як і останні показники. Але також можна побачити аномальні результати, які отримані в результаті прогнозу. На рис. 2.14 можемо бачити різницю між результатами [5].




Рис. 2.14. Виявлення аномальних показників даних за допомогою прогнозування нейронною мережею

Дані результати отримані після проведення 29 тисяч ітерацій при 90 % помилок. У підсумку можемо сказати, що розробка даної архітектури нейронної мережі та підхід до розв'язання задач шляхом безперервного навчання в реальності надасть змогу підтримувати систему в ідеальному стані [5].

Переходимо до п'ятої задачі прогнозування за допомогою штучних нейронних мереж – прогнозування випуску продукції [11].

Якщо коротко, то дана задача є доволі популярною для того, щоб спрогнозувати можливості підприємства по випуску продукції, а також для того щоб зрозуміти майбутню стратегію підприємства, зрозуміти чи справді підприємство є прибутковим чи збитковим. Для цього підприємства і замовляють експертів-аналітиків, які проводять ці дослідження.

Для того, щоб почати проектувати дослідження прогнозування нейронної мережі, потрібно визначити що буде на вході і на виході, а саме які дані. На вході потрібні наступні дані:

- кількість товару одного виду продукції, що був реалізований за певний період, у нашому випадку позначатимемо його x_1 ;
- відсоток залишку цього виду продукції на кінець визначеного періоду – x_2 ;
- питома вага даної продукції в загальному обсязі випуску за певний період – x_3 ;
- витрати часу на виробництво однієї одиниці цього виду продукції – x_4 ;
- сезонність в інтервалі від одиниці до чотирьох у залежності від того, на скільки сезонів розрахований даний вид продукції – x_5 ;
- результат фокусної групи (від 0 до 1), який характеризує думку покупців відносно даного виду продукції – x_6 . Цей параметр показує вплив фактора моди на процес прогнозування випуску продукції;
- приналежність цього виду продукції до першої, другої або третьої категорії потреби населення – x_7 ;

- кількість кольорів, в яких даний вид продукції випускається. Назвемо цей показник індекс кольоровості, який приймає значення від 1 до 7 – x_8 ;

- економічний показник, що характеризує ситуацію в нашій країні – ВВП – x_9 .

На виході повинні отримати кількість одного виду продукції. Провівши реалізацію маємо на вхід 9 параметрів, на вихід 1. Щодо даних, то вони беруться за попередній рік, як і будь-яка мережа. Проектування здійснювалося в середовищі MATLAB, де були використані функції `newff()`, `newcf()`, `newrb()`, які у свою чергу застосовувалися для проектування мереж, де за мету ставилося проектування нейронних мереж з метою порівняння результатів навчання. Архітектуру самої мережі було використано прямої дії, нижче на рис. 2.15. показано схему самої мережі [11].




Рис. 2.15. Архітектура нейронної мережі для вирішення задачі прогнозування випуску продукції

На даній архітектурі ми можемо побачити, що є 9 входів із 36 нейронами, а також 2 прихованих шари, в яких налічується 18 і 9 відповідно

нейронів, а вихід один. Що стосується прогнозу, то він був здійснений у середовищі MATLAB **[11]**.

Висновки до розділу 2

Прогнозування є досить популярним алгоритмом застосування штучних нейронних мереж. Багато компаній для ефективності роботи аналітиків використовують прогнозування.

З опису і дослідження задач прогнозування можемо зробити висновок, що прогнозування за допомогою штучних нейронних мереж застосовується в різних сферах суспільства, чи то банківська і фінансова справа, чи то галузь енергетики, чи виробництво продукції різних видів, чи то сфера перевезень і багато інших. Проаналізувавши дані задачі, можна помітити, що отримані прогнози здійснювалися різними методами, а результати були доволі точними. Тому можна сказати, що прогнозування буде розвиватися та ставати доволі важливим та незамінним в різних сферах.

РОЗДІЛ 3. ПРАКТИЧНА ЧАСТИНА: ПРОГНОЗУВАННЯ НА РИНКУ ПАЛЬНОГО

3.1. Актуальність та фактори, що впливають на ціноутворення

В наш час пальне – один із найважливіших ресурсів, який на даний момент існує на планеті, простими словами це один із двигунів, який рухає світ. Зараз дуже важко уявити сучасний світ без пального, адже це забезпечує рух автотранспорту, авіатранспорту, роботу підприємств, заводів тощо, забезпечуючи їх життєдіяльність. Хоч зараз світ і схиляється до альтернативних джерел енергії, як на заміну пальному, зокрема вітряна електроенергія та зелена (сонячна), але попит на пальне ніколи не згасне. На даний момент відомо безліч видів цього корисного здобутку людства. Що стосується України, ринок пального залишається надзвичайно важливим і динамічно змінюється. Серед різних видів пального, бензин та дизель лишаються найбільш популярними. Навіть при наростаючій популярності електричних та гібридних автомобілів, бензин залишається потрібним на українському і світовому ринку. Дизельне пальне також залишається важливим, особливо в сільському господарстві та вантажоперевезеннях. Хоч і людство намагається прагнути зменшити використання не екологічного пального, а збільшити більш екологічне, а саме зелену енергетику, проте повноцінної заміни досі не знайдено, а компанії котрі вироблять його постійно працюють над поліпшенням і удосконаленням їх якості. В Україні зараз це питання є дуже нагальним, оскільки перевезення за часів війни зростають і багатьох зараз дуже турбує ціна на бензин і дизель, не лише компанії, а й простих громадян. Тому для прогнозування обрано дану тематику, оскільки вона є в наш час доволі хвилюючою і актуальною. Але щоб почати прогнозувати, потрібно провести дослідження факторів, що впливають на ціну на бензин та зібрати дані для дослідження. Їх ми будемо

брати з офіційних джерел, які опубліковані державою та незалежними засобами масової інформації.

На ціноутворення впливають багато факторів, зокрема:

- попит;
- логістичні витрати;
- дистриб'юторські та роздрібні націнки;
- податки та акцизи;
- курс валют;
- світові ціни на нафту.

Розглянемо ці фактори.

Попит. До початку повномасштабної війни попит в Україні, був доволі середнім і стабільним. Після початку війни, перші місяці попит на бензин і дизель був дуже високий, а коли у травні-червні 2022 року він став у дефіциті, то потреба у ньому була шалена. Це зумовлювалось тим, що в перші дні війни виникла шалена міграція людей, які втікали від війни, а також тим, що росія знищила нафтопереробні заводи в Україні, а також регулярно обстрілювала нафтосховища; також попит на генератори через відключення світла. А також величезним фактором стало те, що основним споживачем пального стали Збройні Сили України і з урахуванням дефіциту Україна почала імпортувати бензин і дизельне пальне. Згідно з цими усіма подіями і так далі, ціни постійно коливалися, то йшли вгору, то вниз.

На даний момент часу попит зменшився, оскільки багато користувачів автотранспорту поповнили лави ЗСУ, а велика частина виїхали за кордон. І якщо дивитися на майбутні прогнози на 2024 рік, то має бути стабільне плато. Щодо обсягів продажів, то в порівнянні з попередніми роками на роздрібному ринку в Україні цього року продажі зросли.

Логістичні витрати. Транспортування і зберігання пального також можуть впливати на його ціну. Вартість доставлення, зберігання і розподілу пального включено до його роздрібною вартості. А оскільки зараз війна триває і через обстріли потрібно більш надійні місця зберігання та надійніше

прокладати логістику, то це питання стає все більш нагальним. Бо компанії, які займаються постачанням пального, витрачають колосальні кошти на прокладання логістики та затрати на доставку до місця зберігання, зокрема заправити бензовоз. А враховуючи сучасні реалії, то Україна буде підземні сховища з багаторівневою системою захисту і так далі. Кожен постачальник встановлює свою ціну на постачання пального.

Дистриб'юторські та роздрібні націнки. Компанії, що займаються постачанням і продажем пального, включно з дистриб'юторами та роздрібними мережами АЗС, встановлюють свої націнки на пальне і вони здебільшого мають високе коливання в порівнянні один з одним і кожен власник АЗС сам регулює націнку, але спочатку її встановлює Кабінет міністрів України, а він у свою чергу постановив встановити дозвільну націнку на пальне на 40%, це десь буде становити приблизно 4,55 до 6,50 з урахуванням ПДВ. Але ми маємо розуміти, що Кабінет міністрів також встановлює граничні межі обрахування і націнки, але перед тим питанням займається міністерство економіки. А дана границя націнки постійно коливається.

Податки та акцизи. Державні мита, які встановлюються кабінетом міністрів також відображаються на цінах на пальне, останні зміни до встановлення відбулися 01.07.2023, де Кабінет міністрів встановив наступні ставки акцизного податку:

- Скраплений газ, бутан, ізобутан – 52 євро за 1000 л.
- Бензин, моторні, важкі дистиляти, а також інші нафтопродукти – 100 євро за 1000 л.

А вже з 01.07.2023 було прийнято положення до закону:

- На бензин ціна зростає зі 100 євро до 213,5 євро за 1000 літрів.
- На дизельне палильне зі 100 євро до 139,5 євро за 1000 літрів.
- На скраплений газ, залишається акциз незмінний 52 євро за 1000 літрів.

Що стосується акцизів, то ставка ПДВ з 01.07.2023 на нафтопродукти також зросла із 7 % до 20%, це обумовлено перш за все війною і тим, що

нафтопереробні заводи в Україні перестали працювати через пошкодження, ставка повернулася на довоєнний рівень, ввезення цих паливних продуктів оподатковується за новими тарифами. Але дані тарифи на ПДВ застосовуються до підприємств та простих споживачів, якщо ж замовником є Міністерство оборони України, то акцизний податок становить 0 євро за 1000 літрів.

Курс валют. Що стосується курсу валют, то він також має суттєвий вплив на ціноутворення на пальне. Це є одним із важливих критеріїв, що суттєво впливає на здорожчання чи здешевлення пального. Враховуючи те, що ми в основному імпортуємо нафтопродукти, то тут дуже велика залежність від курсу гривні до долара.

Світові ціни на нафту. Враховуючи те, що зараз війна і нафтопереробні заводи не працюють та Україна є імпортером нафти, то звісно ціни залежать від світових котирувань на нафту. І тому Україна напряму залежить від цін на нафту, бензин і так далі, яка є у світі.

3.2. Вхідні дані для дослідження

Що стосується світового ринку нафти, то дані бралися із порталу Міністерства економіки і Міністерства фінансів, де в режимі реального часу котируються світові ціни на нафту. Для дослідження обрано період із 11.09.2023 по 07.12.2023, беручи прогноз щонеділі. На рисунку 3.1 наведено приклад із сайту.

Ціни на нафту еталонних марок на 8.12.2023

Марка	Ціна (USD/bbl)
Brent	
Brent Crude Oil	75,90 +1.64 +2.21%
WTI	
Light Sweet Crude Oil	71,23 +1.71 +2.46%
Urals	
Urals Oil	(на 7.12.2023) 56,48 -0.26 -0.46%

інформація на 8.12.2023, 15:21 EST (GMT-5)

Рис. 3.1. Ціни на нафту із порталу Мінфіну

З рис. 3.1 можемо бачити ціни на нафту станом на 08.12.2023, у реальному часі. На даний момент найпопулярнішою маркою є Brent, тому згідно неї ми і будемо брати дані і проводити дослідження. На порталі також відомо і ціни за минулі роки. На рисунку 3.2 наглядна діаграма того, як коливається ціна на нафту по датах.

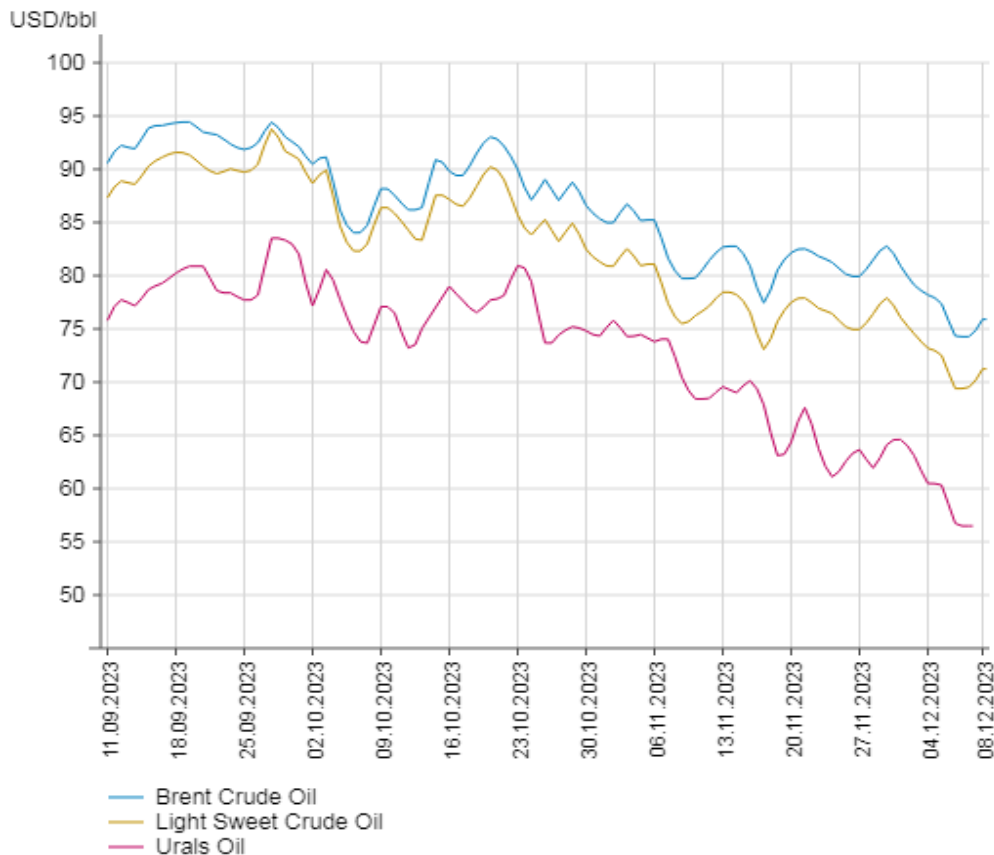


Рис. 3.2. Графік коливання ціни на нафту

Що стосується ціни на бензин, то взято до прикладу А-95 і дані також взято з порталу Мінфіну. Причому, з таким самим періодом вибірки з 11.09.2023 по 07.12.2023, де також йде щоденний моніторинг.

Щодо курсу валют, то він брався із сайту Національного банку України, де ми можемо задати період курсу валют, обрати будь-яку валюту і побачити графік коливань. І це ми можемо бачити у реальному часі. Графік коливань валют подано на рисунку 3.3.

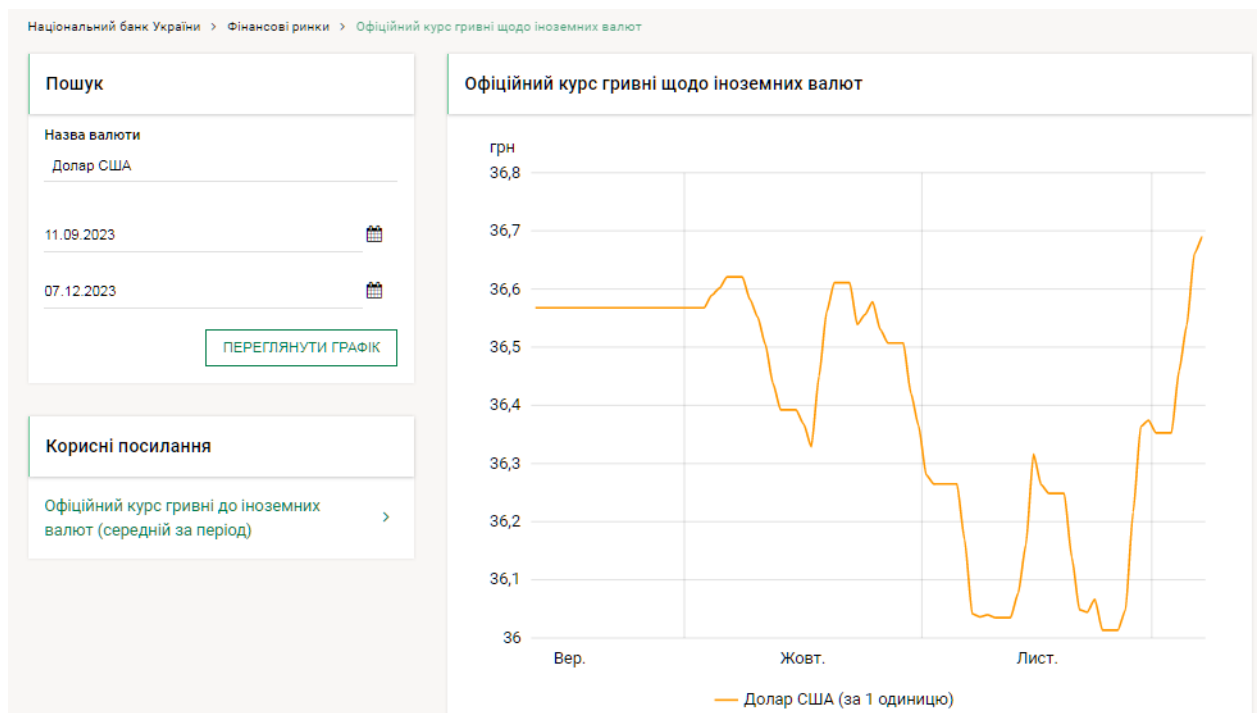


Рис. 3.3. Графік коливань валют

3.3. Результати дослідження

Дослідження проводилося в середовищі для створення нейромереж Neural Network Wizard. Neural Network Wizard – це програмний емулятор нейрокомп'ютера. В Neural Network Wizard реалізовано багатоварову нейронну мережу, що навчається за алгоритмом зворотного поширення похибки (back propagation). Програма може застосовуватися для аналізу

інформації, побудови моделей процесів і прогнозування. У використанні даний емулятор дуже простий. Для цього потрібно лише: зібрати статистику, навчити нейромережу на приведених даних, перевірити отримані результати.

Що стосується можливостей даного емулятора, то вони наступні:

- отримання даних для навчання з текстового файлу;
- різні способи нормування даних;
- створення багатошарових нейронних мереж різної конфігурації;
- налаштування параметрів навчання нейросистеми;
- можливість зберегти результати навчання;
- автоматизація навчання системи;
- автоматичне формування навчальної і тестової множини;
- відкриті вихідні тексти програмного коду.

Щоб розпочати дослідження потрібно мати вхідні дані. Які саме дані потрібні описано у попередньому підрозділі. Це: дата, місяць, рік, ціна на бензин А-95, ціна на нафту, акцизна ставка та курс долара щодо гривні. Вхідні дані представимо у таблиці 3.1.

Таблиця 3.1

Вхідні дані

Data	Month	Year	AveragePriceA95	PriceOil	FuelTax	ExchangeRate
11	09	2023	53.27	90.59	0.2	36.56
18	09	2023	54.20	94.37	0.2	36.56
25	09	2023	54.78	91.85	0.2	36.56
02	10	2023	55.23	90.48	0.2	36.56
09	10	2023	55.41	88.16	0.2	36.58
16	0	2023	55.51	89.8	0.2	36.36
23	10	2023	55.61	89.99	0.2	36.54
30	10	2023	55.56	86.6	0.2	36.17
06	11	2023	55.47	85.24	0.2	36.17
13	11	2023	55.47	82.69	0.2	36.07

20	11	2023	54.90	82.15	0.2	36.13
27	11	2023	54.37	79.93	0.2	36.04
04	12		54.07	78.2	0.2	36.46
07	12		53.65	74.05	0.2	36.69

Після того як сформулювали вхідні дані, можемо переходити до прогнозування. Дані знаходяться у текстовому файлі Doslidzenya.txt. Заходимо у програму Neural Network Wizard і обираємо файл із вхідними даними. Скріншот запуску програми подано у *додатку А*.

Після завантаження текстового файлу із даними для дослідження переходимо до характеристик для кожного поля і першим ми задаємо характеристики для поля Data. Воно є вхідне поле без нормалізації. Було задано сталі значення від 1 до 31 із кроком 1. Скріншот характеристик поля Data наведено у *додатку Б*.

Далі розглянемо поле Month. Воно є вхідним без параметрів нормалізації зі сталими значеннями від 1 до 12 з кроком 1. Скріншот характеристики поля Month подано у *додатку В*.

Після опису полів у яких зберігаються дати, переходимо до опису поля PriceOil (Ціна на нафту). Це є вхідне поле із функцією нормалізації $(X-MIN)/(MAX-MIN)$ із діапазоном полів від 0.5 до 105.5. Опис подано у *додатку Г*.

Надалі ми розглянемо вхідне поле FuelTax (Акцизна ставка), яке є полем без нормалізації із сталим значенням 0.2. Деталі про його можливості можна побачити у *додатку Д*.

Далі на розгляді поле ExchangeRate (Курс валюти), воно є вхідним нормалізованим як $1/(1+\exp(-ax))$ із параметрами нормалізації від 20 до 50. Деталі про поле ExchangeRate наведено у *додатку Е*.

Вхідне поле AveragePriceA95 є цільове (*додаток Є*), оскільки ми виводимо інформацію на екран, воно є вихідне поле. Поле є нормалізоване $(X-MIN)/(MAX-MIN)$, параметри нормалізації від 0.01 до 100.02.

Після визначення полів переходимо до побудови самої нейромережі. Починаємо із задання числа нейронів на вході і на виході, а також задаємо число прихованих шарів:

- число нейронів на вході : **6**;
- число нейронів на виході : **1**;
- число прихованих шарів нейромережі: **1**;

Число нейронів у прихованих шарах 16. Після чого задаємо сигмоїду і її параметри (додаток Ж).

Далі переходимо до задавання параметрів навчання самої нейромережі. До цих параметрів входять: відсоток вибірки, швидкість навчання нейромережі, момент, параметри розпізнавання. А також найважливіше, – це звісно критерій зупинки навчання, до якого входять: кількість епох, максимальна помилка при навчанні, середня помилка при навчанні, кількість відсотків розпізнаної вибірки, максимальна помилка тестування, середня помилка при тестуванні, кількість розпізнаної вибірки. Після того, як задали усі параметри для навчання вибірки. виконуємо наступний крок (натискаємо Далі). Для дослідження достатньо всього лишень 80% вибірки, що дасть більш точний прогноз, а також важливим аспектом є кількість заданих епох (задамо 25), який дасть наглядний стан справ, при швидкості навчання 0.1. Після цього відкриються загальні параметри нейромережі. Усі параметри для навчання проілюстровані в *додатках 3 та К*.

Коли всі дані і налаштування нейромережі здійснено, можна запускати на навчання і аналізувати результати (*додаток Л*). Там ми можемо побачити графік за 25 тижнів і, що на 12-ому тижні буде найбільший пік зростання цін на бензин. Можливо це буде пов'язано із збільшенням цін на нафту і так далі чи коливанням курсу долара до гривні. Детальний результат представлено у *додатку М*.

А вже на завершальному етапі можемо зробити прогноз на певну дату. У даному випадку ми можемо побачити, що задавши усі параметри,

приблизні параметри ціни на нафту, курсу валют, податків на акциз і так далі можемо побачити, що прогнозована ціна становить 44,89 грн.

Висновки до 3 розділу

Сфера енергоресурсів та їх ціноутворення стає дедалі популярнішою, зокрема в Україні. Враховуючи велику кількість споживачів нафтопродуктів і фактор війни, то проблема з ціноутворенням є доволі нагальною. Саме тому прогнозування за допомогою нейронних мереж є ефективним. Для прикладу розглянуто один найпопулярніших видів пального – бензин А-95.

Проаналізувавши ціни за попередній період, із періодичністю в 1 тиждень, зокрема за даними на сайті Міністерства фінансів і економіки України, взявши до уваги курс валют за попередній період із офіційного сайту Національного банку України, врахувавши важливі параметри – акцизну ставку та ціни на нафту за попередній період та провівши колосальну роботу із визначення факторів, які здійснюють безпосередній вплив на ціноутворення, та збору даних, здійснили прогнозування ціни на бензин А-95 на 2024 рік в середовищі для побудови нейронних мереж Neural Network Wizard і отримали доволі точний прогноз.

ВИСНОВКИ

Аналітика і прогнозування, присутні у будь-якій сфері життєдіяльності (виробництво, маркетинг і менеджмент, фінансова структура тощо) стали її невід'ємною частиною, оскільки це дає можливість ефективно використовувати можливості, а також передбачати усі можливі наслідки та знати, як на них реагувати. Як видно з досліджень, прогнозування просякнуло кожен сферу життєдіяльності і все більше компаній наймають на роботу експертів із прогнозування, а вже вони у свою чергу обирають метод прогнозування.

На сьогоднішній день, як ми знаємо, набирає популярності штучний інтелект, зокрема штучні нейронні мережі, які дають доволі точні прогнози і методи вирішення проблеми.

Штучні нейронні мережі, являють собою математичні моделі, а також їх програмні або апаратні реалізації, побудовані за принципом організації й функціонування біологічних нейронних мереж – мереж нервових кліток живого організму або простіше кажучи це спроба відтворення роботи людського мозку на комп'ютері за допомогою шарів нейронів. Основною перевагою нейронних мереж є можливість їх навчання. За увесь час було створено багато видів нейронних мереж і застосовано їх до розв'язування тих чи інших задач. Популярність здобули дослідження, пов'язані з прогнозуванням.

У даній кваліфікаційній роботі ми розглянули і описали деякі задачі прогнозування за допомогою штучних нейронних мереж, що стосуються багатьох сфер життєдіяльності і прийшли до висновку, що хоча прогнозування здійснювалося різними методами і у різних середовищах програмування, але це не вплинуло на точність отриманих результатів.

Також в рамках теми дослідження практично розглянуто задачу прогнозування ціноутворення на паливо в Україні, а саме на бензин А-95, для

чого виконано аналітику і збір даних. Прогнозування здійснено у середовищі Neural Network Wizard і отримано прогноз, зокрема на певну дату.

В підсумку можна сказати, що застосування прогнозування за допомогою нейронних мереж у різних задачах, з часом все більше набиратиме популярності, як і сам штучний інтелект, оскільки це дасть змогу дуже влучно вибудовувати стратегії та розуміти усі ризики.

СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. Акіменко В.В. Штучні нейронні мережі в задачах групування та аналізу інформації [Електронний ресурс] Київ : Київський національний університет імені Тараса Шевченка, 2020, С. 2-9, 44-55 URL: https://csc.knu.ua/media/study/asp/art_net_group_inf_akimenko/lecture/lec1.pdf
2. Бородін О.І Використання нейронних мереж для кредитного скорингу підприємства [Електронний ресурс] Миколаїв : Чорноморський національний університет імені Петра Могили, 2022, С. 6-12, 58-68 URL: <https://krs.chmnu.edu.ua/jspui/bitstream/123456789/2339/1/401%20%D0%91%D0%BE%D1%80%D0%BE%D0%B4%D1%96%D0%BD%20%D0%9E%D0%BB%D0%B5%D0%BA%D1%81%D0%B0%D0%BD%D0%B4%D1%80%20%D0%86%D0%B3%D0%BE%D1%80%D0%BE%D0%B2%D0%B8%D1%87.pdf>
3. Вернигора Р.В., Єльнікова Л.О., Науковий вісник “Можливості використання штучних нейронних мереж при прогнозуванні поїзної роботи залізничних напрямків” [Електронний ресурс] Дніпро : Дніпропетровський національний університет залізничного транспорту імені академіка В. Лазаряна, 2014, С. 2-5, URL: <https://cyberleninka.ru/article/n/mozhливosti-vikoristannya-shtuchnih-neyronnih-merezh-pri-prognozuvanni-poyiznoyi-roboti-zaluznichnih-naryamkiv/viewer>
4. Гончаренко В.А. Наукові записки. Випуск 16. Прогнозування дохідності цінних паперів на підґрунті застосування інструментарію нейронних мереж [Електронний ресурс] Київ : Київський національний економічний університет, 2011, С. 576-584 URL: <https://eprints.oa.edu.ua/id/eprint/7081/1/78.pdf>
5. Карпа Д.М., Цмоць І.Г., Опотняк Ю.В., Науковий вісник НЛТУ України “Нейромереві засоби прогнозування споживання енергоресурсів” [Електронний ресурс] Львів : Національний університет “Львівська політехніка” 2018, С. 140-144. URL: https://www.researchgate.net/publication/326536701_Nejromerezevi_zasobi_prog

nozuvanna_spozivanna_energoresursiv/fulltext/5b53340c0f7e9b240ff90d61/Nejro
merezevi-zasobi-prognozuvanna-spozivanna-energoresursiv.pdf

6. Картаполов Д.М. Науковий вісник “Прогнозування страхового випадку за допомогою нейронних мереж” [Електронний ресурс] Херсон : Херсонський національний технічний університет, 2021, С. 154-159 URL: http://www.econom.stateandregions.zp.ua/journal/2018/5_2018/24.pdf

7. Козаков В.В. Штучні нейронні мережі та їх застосування в задачах прогнозування. Збірник матеріалів наукової конференції здобувачів вищої освіти фізико-математичного факультету Кам’янець-Подільського національного університету імені Івана Огієнка. 1 листопада 2023 року [Електронний ресурс]. Кам’янець-Подільський : Кам’янець-Подільський національний університет імені Івана Огієнка, 2023. С. 36-37

8. Козаков В.В., Пилипюк Т.М. Штучні нейронні мережі та їх застосування в задачах прогнозування. Вісник Кам’янець-Подільського національного університету імені Івана Огієнка. Фізико-математичні науки. Випуск 16. Кам’янець-Подільський : Кам’янець-Подільський національний університет імені Івана Огієнка, 2023. С. 38-42.

9. Малюта Ю. Прогнозування за допомогою штучних нейронних мереж, С. 2-9

URL: https://elartu.tntu.edu.ua/bitstream/123456789/401/6/PE2010-Presentation-Maluta_Y-Prediction_using_neural_networks.pdf

10. Соботович М., Мартинюк О., Використання штучних нейронних мереж в задачі короткострокового прогнозування споживання активної потужності населенням [Електронний ресурс] Київ : Національний університет харчових технологій, 2014, С. 370-371 URL: <https://eprints.oa.edu.ua/id/eprint/7081/1/78.pdf>

11. Солодуха О.В. Використання нейронних мереж для вирішення задачі прогнозування випуску продукції [Електронний ресурс] Донецьк : Донецький національний технічний університет, 2009, С. 484-488 URL:

<https://drive.google.com/drive/u/2/folders/1DBkRd0U9bBY6VXxFhcG7iBwbZRs-AL7C>

12. Тригуба А., Тригуба І., Чубик Р., Кондисюк І., Коваль Н., Панюра Я. Прогнозування обсягів заготівлі сировини на території громад із використанням штучних нейронних мереж [Електронний ресурс] Дубляни : Львівський національний аграрний університет, 2020, С. 143-148, URL: <https://visnyk.lnup.edu.ua/index.php/agroengineering/article/download/118/105/124>

13. Фадєєва І.Г. Прогнозування собівартості буріння нафтових і газових свердловин на засадах синергетики [Електронний ресурс] Івано-Франківськ : Івано-Франківський національний технічний університет нафти і газу 2010, С. 144-151

URL: http://journals.khnu.km.ua/vestnik/pdf/ekon/2010_4_4/144-152.pdf

14. Франчук А.Ю. Прогнозування мережевого трафіку в системах безпеки з використанням нейронних мереж [Електронний ресурс] Вінниця : Вінницький національний технічний університет, 2013, С. 4-25, URL: <https://inmad.vntu.edu.ua/portal/static/8D3679F0-B42E-4867-9620-827A7DD7ED1C.pdf>

15. Використання нейронних мереж – перспективна сфера науки і суспільства URL: <http://oldconf.neasmo.org.ua/node/139>

16. Динаміка цін на пальне в Україні за останні роки. Аналіз ринку, прогнози. URL: <https://ryderukraine.com/newsblog/dynamika-tsin-na-palne-v-ukraini-za-ostanni-roky-analiz-rynku-prohnozy/>

17. Націнки на пальне, 2022 URL: <https://suspilne.media/234258-kabmin-pidnav-dozvilnu-nacinku-na-palivo-ce-dopomoze-podolati-deficit-palnogo-na-azs/>

18. Нові ставки акцизу на деякі види палива. URL: <https://buhplatforma.com.ua/news/66138-z-1-lipnya-diyut-novi-stavki-aktsizu-na-deyaki-vidi-paliva>

19. Огляд ринку пального в Україні: важливі тенденції, 2023 URL: <https://www.linkedin.com/pulse/%D0%BE%D0%B3%D0%BB%D1%8F%D0%B>

4-%D1%80%D0%B8%D0%BD%D0%BA%D1%83-
 %D0%BF%D0%B0%D0%BB%D1%8C%D0%BD%D0%BE%D0%B3%D0%BE
 -%D0%B2-%D1%83%D0%BA%D1%80%D0%B0%D1%97%D0%BD%D1%96-
 %D0%B2%D0%B0%D0%B6%D0%BB%D0%B8%D0%B2%D1%96-
 %D1%82%D0%B5%D0%BD%D0%B4%D0%B5%D0%BD%D1%86%D1%96%
 D1%97-artur-slobozhaninov-tsg7e?trk=article-ssr-frontend-pulse_more-
 articles_related-content-card

20. Офіційний курс гривні щодо іноземних валют. URL:
<https://bank.gov.ua/ua/markets/exchangerates>

21. Типи штучних нейронних мереж URL:
https://uk.wikipedia.org/wiki/%D0%A2%D0%B8%D0%BF%D0%B8_%D1%88%D1%82%D1%83%D1%87%D0%BD%D0%B8%D1%85_%D0%BD%D0%B5%D0%B9%D1%80%D0%BE%D0%BD%D0%BD%D0%B8%D1%85_%D0%BC%D0%B5%D1%80%D0%B5%D0%B6

22. Фактори, що впливають на ціну пального. URL: <https://ua-energy.org/uk/posts/na-tsinu-palnoho-v-ukraini-vplyvaie-try-factory-ekspert-dixi-group>

23. Ціни на бензин.

URL: <https://www.epravda.com.ua/publications/2022/02/9/682204/>

24. Ціни на бензин, дизпаливо, газ на АЗС України.

URL: <https://index.minfin.com.ua/ua/markets/fuel/>

25. Ціни на пальне за останні 3 місяці.

URL: <http://www.nrcu.gov.ua/news.html?newsID=102478>

26. Штучна нейронна мережа

URL:

https://uk.wikipedia.org/wiki/%D0%A2%D0%B8%D0%BF%D0%B8_%D1%88%D1%82%D1%83%D1%87%D0%BD%D0%B8%D1%85_%D0%BD%D0%B5%D0%B9%D1%80%D0%BE%D0%BD%D0%BD%D0%B8%D1%85_%D0%BC%D0%B5%D1%80%D0%B5%D0%B6

27. Штучні нейронні мережі, с.2-5 URL:
https://learn.ztu.edu.ua/pluginfile.php/176771/mod_resource/content/1/%D0%A8%D0%86_%D0%9A%D0%91_%D0%9B-3_%D0%9D%D0%B5%D0%B9%D1%80%D0%BE%D0%BC%D0%B5%D1%80%D0%B5%D0%B6%D0%B8.pdf

28. Що варто знати про ціни на паливо?

URL: <http://oilers.org.ua/uk/2018/03/16/shho-varto-znati-pro-cini-na-palivo/>

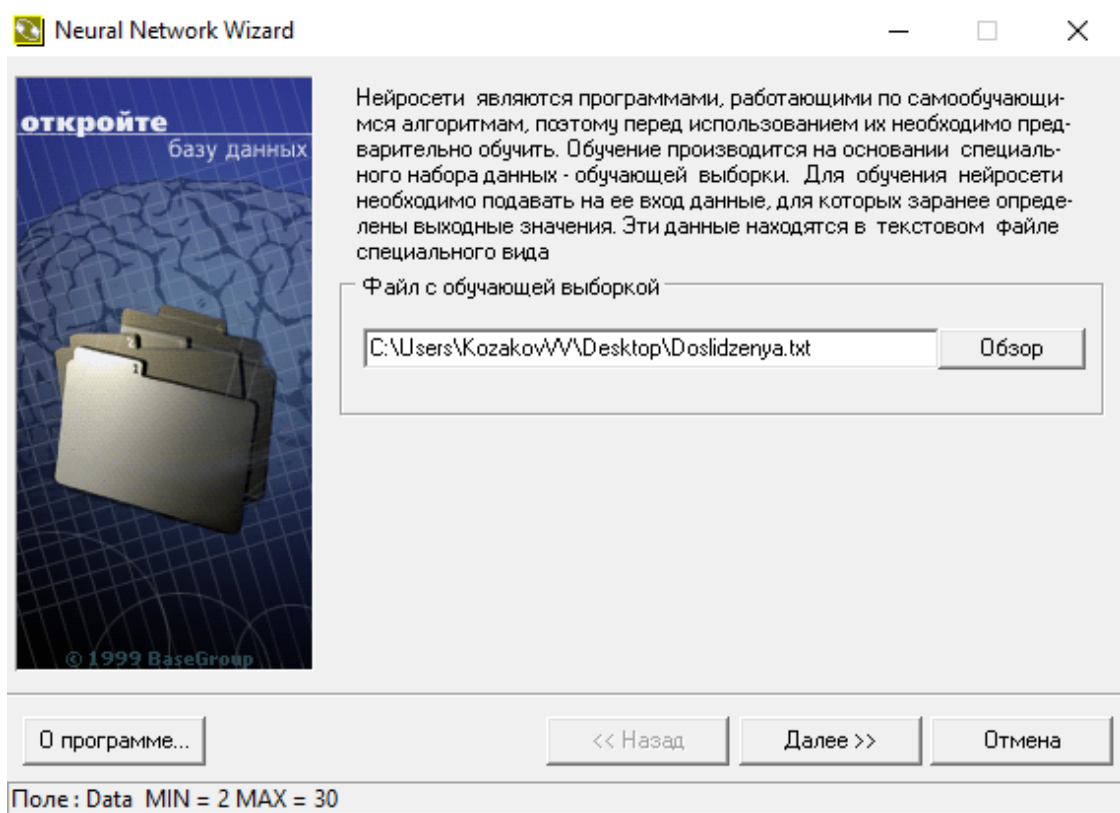
29. Що впливає на вартість пального

URL: <https://suspilne.media/206174-so-vplivae-na-vartist-palnogo-roasnue-ekspert/>

ДОДАТКИ

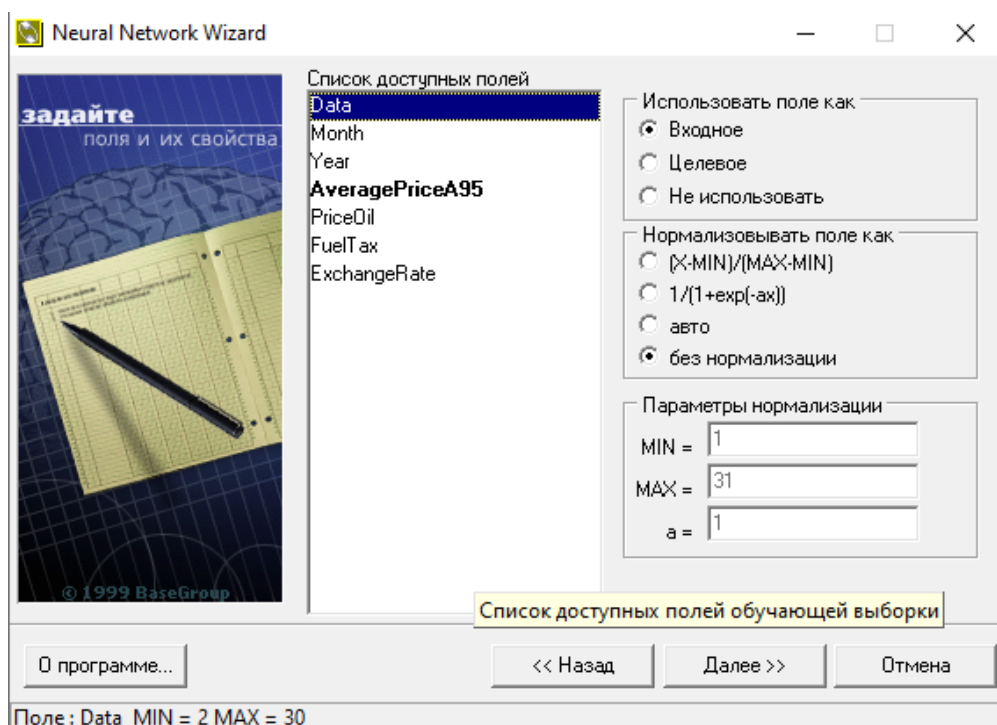
Додаток А

Запуск программы Neural Network Wizard



Додаток Б

Характеристики для поля Data



Характеристики для поля Month

Neural Network Wizard

задайте поля и их свойства

© 1999 BaseGroup

Список доступных полей

- Data
- Month
- Year
- AveragePriceA95
- PriceOil
- FuelTax
- ExchangeRate

Использовать поле как

- Входное
- Целевое
- Не использовать

Нормализовать поле как

- $(X-MIN)/(MAX-MIN)$
- $1/(1+\exp(-ax))$
- авто
- без нормализации

Параметры нормализации

MIN = 1

MAX = 12

a = 1

О программе... << Назад Далее >> Отмена

Поле : Month MIN = 9 MAX = 12

Характеристики для поля PriceOil

Neural Network Wizard

задайте поля и их свойства

© 1999 BaseGroup

Список доступных полей

- Data
- Month
- Year
- AveragePriceA95
- PriceOil
- FuelTax
- ExchangeRate

Использовать поле как

- Входное
- Целевое
- Не использовать

Нормализовать поле как

- $(X-MIN)/(MAX-MIN)$
- $1/(1+\exp(-ax))$
- авто
- без нормализации

Параметры нормализации

MIN = 0.5

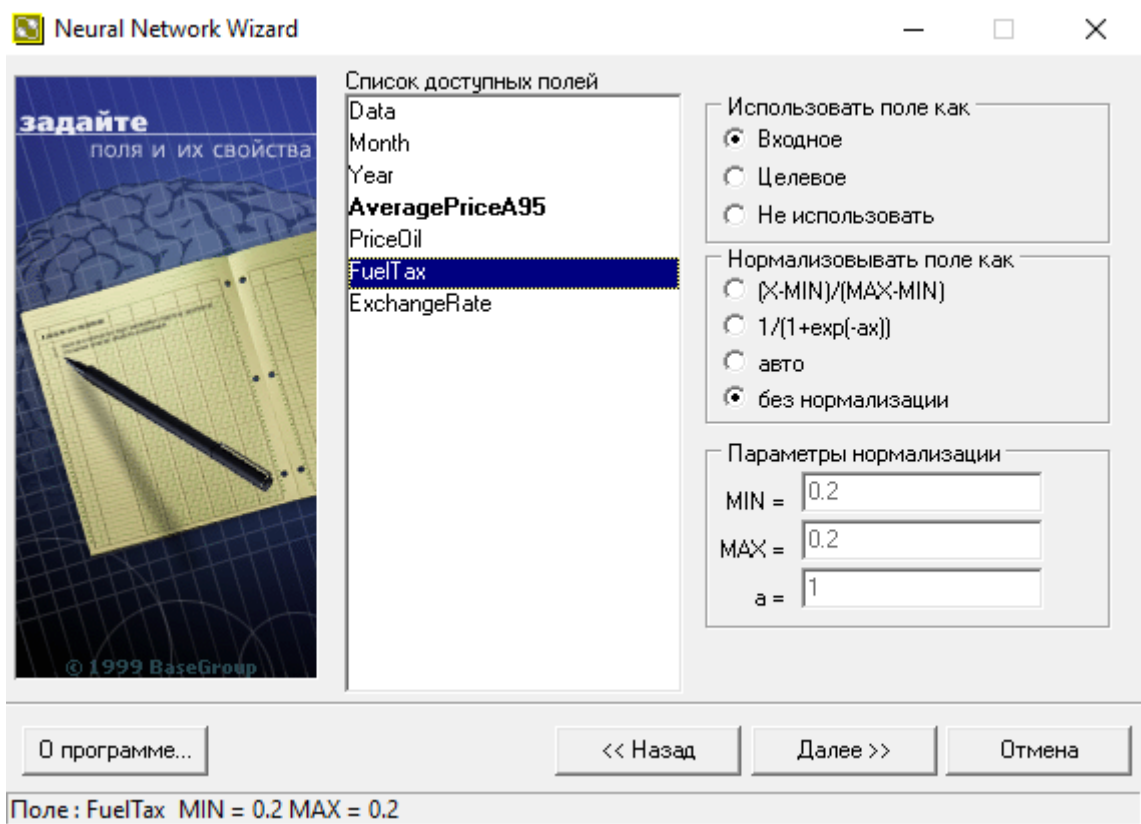
MAX = 105.5

a = 1

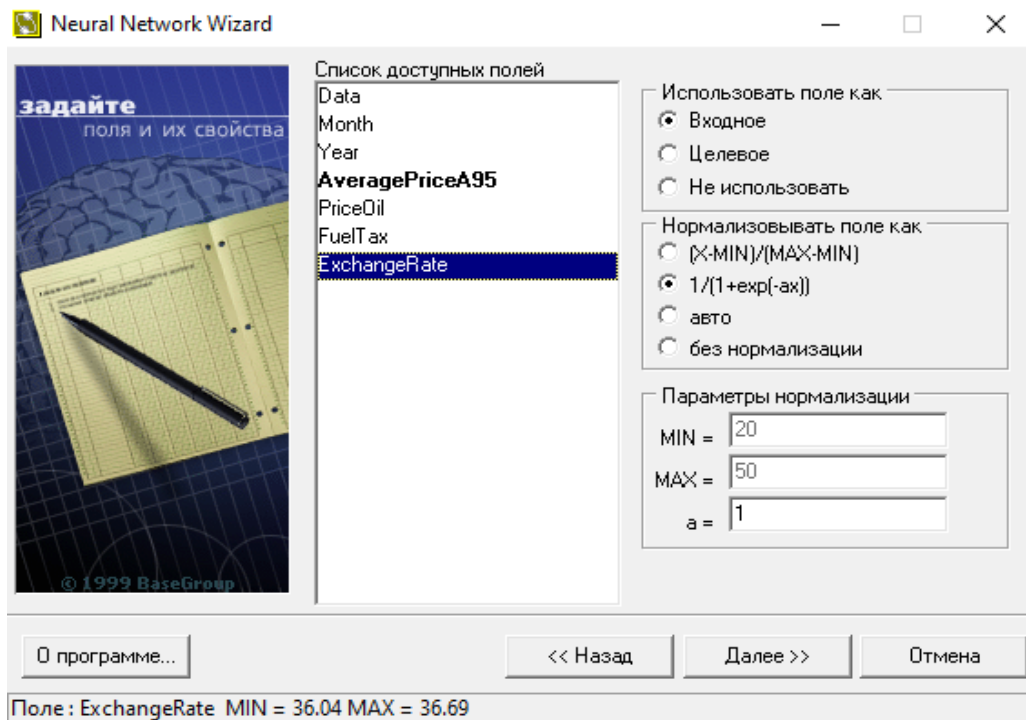
О программе... << Назад Далее >> Отмена

Поле : PriceOil MIN = 74.05 MAX = 94.37

Поле FuelTax та його властивості



Поле ExchangeRate та його властивості



Вхідне поле AveragePriceA95 та його властивості

Neural Network Wizard

задайте поля и их свойства

Список доступных полей

- Data
- Month
- Year
- AveragePriceA95**
- PriceOil
- FuelTax
- ExchangeRate

Использовать поле как

- Входное
- Целевое
- Не использовать

Нормализовать поле как

- $(X-MIN)/(MAX-MIN)$
- $1/(1+\exp(-ax))$
- авто
- без нормализации

Параметры нормализации

MIN =

MAX =

a =

Поле : AveragePriceA95 MIN = 53.27 MAX = 55.61

Параметры сети

Neural Network Wizard

задайте параметры нейросети

число нейронов во входном слое

число нейронов в выходном слое

число скрытых слоев нейросети

#слоя	число нейронов
1	16

Параметр сигмоиды

Вид сигмоиды

Поле : Data MIN = 2 MAX = 30

Параметры для навчання мережі

Neural Network Wizard

задайте параметры обучения

Использовать для обучения нейросети 80 % выборки

Скорость обучения 0.1

Момент 0.9

Распознано если ошибка по примеру < 0.05

Использовать тестовое множество как валидационное

Критерии останова обучения

Прошло 25 эпох

Макс. ошибка при обучении < 0.05

Средняя ошибки при обучении < 0.05

Распознано 80 % обучающей выборки

Макс. ошибка при тестировании < 0.05

Средняя ошибки при тестировании < 0.05

Распознано 80 % тестовой выборки

0 программе... << Назад Далее >> Отмена

Поле : Data MIN = 2 MAX = 30

Параметры для навчання мережі

Neural Network Wizard

проверьте все заданные параметры

Конфигурация нейросистемы
Для обучения используется файл:
C:\Users\Kozakov\W\Desktop\Doslidzenya.txt

В качестве входных полей используются
Data: вход: 0
Month: вход: 1
Year: вход: 2
PriceOil: $x = (X - 0.50) / 105.00$ вход: 3
FuelTax: вход: 4
ExchangeRate: $x = 1 / 1 + \exp(-1.00 * X)$ вход: 5

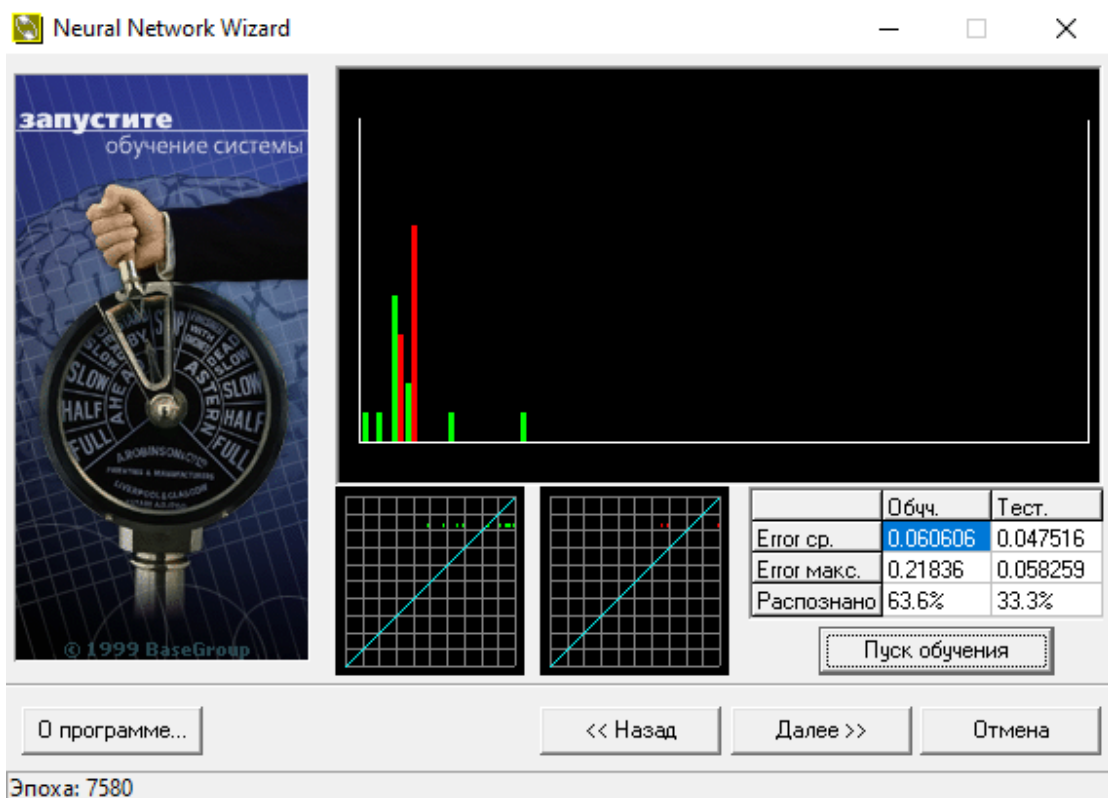
В качестве целевых полей используются
AveragePriceA95: $x = (X - 0.01) / 100.01$ вход: 0

Конфигурация нейросети
Параметр сигмоиды: 1
Число входов: 6
Количество скрытых слоев: 1
Слой 1 - число нейронов: 16
Число выходов: 1

0 программе... << Назад Далее >> Отмена

Поле : Data MIN = 2 MAX = 30

Стартове вікно навчання мережі



Отриманий результат

