

ДЕРЖАВНИЙ УНІВЕРСИТЕТ ТЕЛЕКОМУНІКАЦІЙ

НАВЧАЛЬНО–НАУКОВИЙ ІНСТИТУТ ТЕЛЕКОМУНІКАЦІЙ

Кафедра системного аналізу

Пояснювальна записка

до магістерської роботи

на ступінь вищої освіти магістр

на тему: «ПОБУДОВА ТА НАВЧАННЯ НЕЙРОННОЇ МЕРЕЖІ ДЛЯ
ПРОГНОЗУВАННЯ ПОГОДИ ЗА ДОПОМОГОЮ ПРОГРАМИ NEURON
STUDIO»

Виконав: студент 6 курсу, групи САДМ-61
спеціальності

124 Системний аналіз

(шифр і назва спеціальності)

Ящук Ю.Р.

(прізвище та ініціали)

Керівник Гордієнко Т.Б.

(прізвище та ініціали)

Рецензент _____

(прізвище та ініціали)

Нормоконтроль _____

(прізвище та ініціали)

Київ – 2022

ДЕРЖАВНИЙ УНІВЕРСИТЕТ ТЕЛЕКОМУНІКАЦІЙ

Навчально–науковий інститут телекомунікацій

Кафедра Системного аналізу

Ступінь вищої освіти «Магістр»

Спеціальність підготовки 124, Системний аналіз

ЗАТВЕРДЖУЮ

Завідувач кафедри
Системного аналізу

Т.Б.Гордієнко

“ ” 2022 року

З А В Д А Н Н Я **НА МАГІСТЕРСЬКУ РОБОТУ СТУДЕНТУ**

Ящук Юлії Русланівні

(прізвище, ім'я, по батькові)

1. Тема роботи: Побудова та навчання нейронної мережі для прогнозування погоди за допомогою програми Neuroph Studio

Керівник роботи Гордієнко Тетяна Богданівна, д.т.н., проф.

(прізвище, ім'я, по батькові, науковий ступінь, вчене звання)

затверджені наказом вищого навчального закладу від “ ” 2022 року №

2. Строк подання студентом роботи 25 грудня 2022 року

3. Вихідні дані до роботи

3.1 Науково-технічна література та електронні джерела

3.2 Статистичні дані погоди

3.3 Програмне забезпечення для навчання нейромережі

4. Зміст розрахунково-пояснювальної записки (перелік питань, які потрібно розробити).

4.1. Особливості нейронних мереж

4.2. Аналіз рішень для навчання нейронних мереж

4.3. Кодування статистичних даних погоди

4.4. Розроблення нейромережі

5. Перелік графічного матеріалу

5.1 Об'єкт, мета, предмет магістерської роботи

5.2 Актуальність роботи

5.3 Задачі магістерської роботи

5.4 Що таке нейронна мережа?

5.5 Персептрон

5.6 Кодування початкової інформації

5.7 Частина даних (для Києва)

5.8 Результати навчання по Києву

5.9 Вхідні дані для Оклахома-сіті

5.10 Результати навчання по Оклахома-сіті

5.11 Порівняння результатів навчання

5.12 Апробація роботи

5.13 Висновки

6. Дата видачі завдання 1 листопада 2022 року

КАЛЕНДАРНИЙ ПЛАН

№ з/п	Назва етапів магістерської Роботи	Строк виконання етапів роботи	Примітка
1	Підбір науково-технічної літератури	7 днів	Виконала
2	Пошук інформації про подібне програмне забезпечення для навчання нейронної мережі	5 днів	Виконала
3	Визначення актуальності дослідження	3 дні	Виконала
4	Пошук та аналіз можливостей прогнозування погоди за допомогою нейронних мереж	3 дні	Виконала
5	Збір даних погоди	1 тиждень	Виконала
6	Реалізація системи прогнозування погоди	1 місяць	Виконала
7	Розробка обов'язкових демонстраційних матеріалів	3 дні	Виконала
8	Попередній захист роботи		Виконала
9	Пред'явлення роботи в деканат		Виконала

Студент

(підпис)

Ящук Ю.Р.

(прізвище та ініціали)

Керівник роботи

(підпис)

Гордієнко Т.Б.

(прізвище та ініціали)

ДЕРЖАВНИЙ УНІВЕРСИТЕТ ТЕЛЕКОМУНІКАЦІЙ
ПОДАННЯ
ГОЛОВІ ДЕРЖАВНОЇ ЕКЗАМЕНАЦІЙНОЇ КОМІСІЇ
ЩОДО ЗАХИСТУ МАГІСТЕРСЬКОЇ КВАЛІФІКАЦІЙНОЇ РОБОТИ

Направляється студент Ящук Ю.Р. до захисту магістерської роботи
(прізвище та ініціали)

спеціальності 124 Системний аналіз

(шифр і назва спеціальності)

на тему: «Побудова та навчання нейронної мережі для прогнозування погоди за допомогою програми Neuroph Studio»

Магістерська робота і рецензія додаються.

Директор ННІТ

Кравченко В.І.

(підпис)

Довідка про успішність

Ящук Ю.Р. за період навчання в Навчально-науковому інституті телекомунікацій
(прізвище та ініціали)

з 2021 року до 2022 року повністю виконав навчальний план за напрямом підготовки, магістр, 124, системний аналіз з таким розподілом оцінок за:

національною шкалою: відмінно %, добре %, задовільно %;

шкалою ECTS: A %; B %; C %; D %; E %.

Провідний фахівець інституту

(підпис)

(прізвище та ініціали)

Висновок керівника магістерської роботи

Студентка Ящук Юлія Русланівна показала свою підготовку разом із володінням теоретичного матеріалу із розумінням методики розробки і впровадження програмних засобів, адже якісно вміє володіти новими комп'ютерними технологіями та вміє детально користуватися навчальною, довідковою і науково-технічною літературами. Позитивними рисами дипломної роботи є актуальність, системність та послідовність викладеної інформації. Тема дипломної роботи розкрита, основні положення та висновки достатньо обгрунтовані. Всі поставлені задачі виконано.

Магістерська робота виконана на високому рівні і заслуговує оцінку «відмінно», а студентці Ящук Юлії Русланівні – присвоєння кваліфікації Магістр з системного аналізу.

Керівник роботи

(підпис)

Гордієнко Т.Б.

(прізвище та ініціали)

« » 2022 року

Висновок кафедри про магістерську роботу

Магістерську роботу розглянуто. Студент Ящук Ю.Р. допускається
(прізвище та ініціали)

до захисту даної роботи в Державній екзаменаційній комісії.

Завідувач кафедри Системного аналізу

(назва)

(підпис)

Т.Б. Гордієнко

(прізвище та ініціали)

« » 2022 року

ВІДГУК РЕЦЕНЗЕНТА

на магістерську роботу

студентки Ящук Юлії Русланівни

на тему: «Побудова та навчання нейронної мережі для прогнозування погоди за допомогою програми Neuroph Studio»

Актуальність:

Дослідження є актуальним, тому що на поточний момент все більше і більше вчених починають вивчати погоду за допомогою нейронних мереж для того, щоб точніше виявляти зміни клімату та робити певні висновки. Тому тема розробленої магістерської роботи являється актуальною.

Позитивні сторони:

Магістерська робота виконана відповідно до поставленого завдання та в повному обсязі. В роботі чітко та стисло викладено основні принципи сучасних досліджень нейронних мереж для прогнозування погоди, проведено аналіз існуючих систем. В роботі розроблено нейромережу, яка розраховує ймовірність появи небезпечних погодних явищ. Також проведено порівняння з погодою в американському місті Оклахома.

Магістерська робота, її пояснювальна записка, графічний матеріал виконані з дотриманням відповідних вимог.

Недоліки:

В роботі є незначні помилки, також можна було б представити більше графічних даних.

Висновок: магістерська робота заслуговує оцінку "*відмінно*", а студентка – Ящук Ю.Р. гідний присвоєння кваліфікації магістр з системного аналізу.

Якість магістерської роботи	
виконано на замовлення підприємства	
виконано за тематикою НДР	
виконано з макетом	
має практичну цінність	+

Підпис рецензента

(Прізвище, ініціали)

(посада, науковий ступінь, вчене звання)

ПЕРЕЛІК УМОВНИХ СКОРОЧЕНЬ

НМ – Нейронна Мережа

CNN - Convolutional Neural Network

FFNN - Feed Forward Neural Networks

RNN - Recurrent Neural Network

RMSE – Середньоквадратичне Відхилення

БП – Багатошаровий персептрон

MSE - Total Mean Square Error

LSTM – Long-Short Term Memory

GG – Conjuugate Gradietn

QKP – Quick Propagation

LM – Levenberg-Marquardt

КК – Коефіцієнт кореляції

DBD – Delta-Bar-Delta

STP – Step

MOM – Momentum

РЕФЕРАТ

Текстова частина дипломної роботи: 55 сторінки та включає 13 ілюстрацій, 16 таблиць та 17 інформаційних джерел.

Об'єкт дослідження – аналіз та прогнозування небезпечних погодних явищ на основі статистичних даних.

Предмет дослідження – прогнозування погодних умов та явищ за допомогою нейронної мережі.

Мета роботи – розробити програму для встановлення ймовірності появи небезпечних погодних явищ за допомогою Neuroph Studio.

Методи дослідження – аналіз існуючого програмного забезпечення для навчання нейронної мережі.

Отримані результати – проаналізовано ймовірність появи небезпечних погодних явищ на території Києва та області у порівнянні з даними, які отримані в місті Оклахома (США).

Наукова новизна одержаних результатів – розроблена модель нейронної мережі, яка реалізує прогнозування погодних явищ на основі довгострокових даних. Зараз здебільшого використовуються можливості реалізації короткотривалих прогнозів.

Практичне значення одержаних результатів – за допомогою навченої нейронної мережі можна провести розрахунки і на їх основі робити статистику довгострокової зміни погоди, порівнюючи отримані результати з показниками інших країн. Також цю нейронну мережу можна використовувати за відсутності потужного обладнання.

Апробація роботи відбулась на Міжнародній науковій інтернет-конференції «Інформаційне суспільство: технологічні, економічні та технічні аспекти становлення» (випуск 72), 15-16 листопада 2022 року, МНІК "Конференція онлайн", Тернопіль, Україна.

ЗМІСТ

ПЕРЕЛІК УМОВНИХ СКОРОЧЕНЬ	6
ВСТУП	10
1.АНАЛІЗ МОЖЛИВОСТЕЙ ВИКОРИСТАННЯ НЕЙРОННИХ МЕРЕЖ ДЛЯ ПРОГНОЗУВАННЯ ПОГОДНИХ ЯВИЩ	11
1.1. Поняття нейронної мережі	12
1.2. Види нейронних мереж	13
1.3. Типи завдань, які можуть вирішуватись нейронною мережею	14
1.4. Призначення штучних нейронних мереж при прогнозуванні погодних явищ в реальному житті.....	15
2. ДОСЛІДЖЕННЯ ТЕХНОЛОГІЙ ЗАСТОСУВАННЯ НЕЙРОМЕРЕЖ ТА МЕТОДІВ ЇХ НАВЧАННЯ.....	19
2.1. Класифікація нейронних мереж	19
2.2. Архітектура нейронних мереж	20
2.3. Поняття персептрону	21
2.3.1. Одношаровий персептрон.	21
2.3.2. Багатошаровий персептрон	22
2.4. Як працює персептрон?	22
3. РОЗРОБКА ТА НАВЧАННЯ НЕЙРОННОЇ МЕРЕЖІ ДЛЯ ПРОГНОЗУВАННЯ НЕБЕЗПЕЧНИХ ПОГОДНИХ ЯВИЩ	30
3.1. Вибір програмного забезпечення	30
3.2. Збір даних та їх коригування	30
3.3. Формування навчальної вибірки багатошарового персептрона	31

3.4. Схема нейромережі в Neuroph Studio.....	38
3.5. Реалізація навчання нейромережі.....	40
3.6. Розрахунок ймовірності на значеннях, які не є в навчальній вибірці	42
3.7. Порівняння прогнозування на прикладі з м. Оклахома	43
3.8. Розрахунок ймовірності на значеннях, які не є в навчальній вибірці	46
ВИСНОВКИ	50
СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ	51
Додаток А. Датасет погоди м. Києва для навчання нейромережі	53
Додаток Б. Датасет погоди м. Оклахома для навчання нейромережі	54
Додаток В. Перелік зауважень нормоконтролера	55

ВСТУП

З появою технічних засобів для досліджень, все більше, вчені і не тільки, почали звертати увагу на аналіз погодних явищ, для того, щоб прорахувати зміни клімату, їх вплив на живі організми та рослини.

Дані про погоду і її прогноз мають велике значення для багатьох галузей економіки, зокрема, авіації, будівництві і сільському господарстві, так як планування і проведення багатьох проектів напряду залежить від погодних умов.

Розвиток науки дозволяє широко застосовувати математичні методи в теоретичних дослідженнях атмосфери і клімату. До прикладу, при вирішенні великого списку задач системи штучного інтелекту дозволяють замінити спеціаліста і дають результати, які по якості і ефективності не поступаються рішенням, які отримані експертом.

Актуальність даної розробки полягає в цінності наукових досліджень погоди на основі отриманих даних, оскільки таким чином можна визначити відсоток появи певних явищ у найближчому майбутньому.

По перше, це допоможе зрозуміти наскільки змінився клімат.

По друге, допоможе екологам просунутись у своїх цілях, за допомогою яких вони рекомендують зберігати навколишнє середовище.

Тому, в даній роботі хочеться зацентрувати увагу саме на необхідності досліджень погоди, оскільки багато джерел інформації вказують на невпинні зміни клімату. Також хочеться проаналізувати центральну точку всіх небезпечних подій і зробити порівняння у висновках.

ЗАВДАННЯ ДОСЛІДЖЕННЯ

В рамках магістерської роботи необхідно:

1. Підібрати необхідну технічну літературу
2. Проаналізувати актуальність даної роботи
3. Здійснити пошук інформації про подібне програмне забезпечення для навчання нейронної мережі
4. Зібрати дані погоди за 10 років у Києві та Оклахома-сіті
5. Зробити кодування даних
6. Розробити нейромережу для прорахунку ймовірності погоди в Києві та Оклахома-сіті
7. Порівняти результати навчання
8. Зробити висновки

1. АНАЛІЗ МОЖЛИВОСТЕЙ ВИКОРИСТАННЯ НЕЙРОННИХ МЕРЕЖ ДЛЯ ПРОГНОЗУВАННЯ ПОГОДНИХ ЯВИЩ

1.1. Поняття нейронної мережі

Нейронні мережі – обчислювальні системи чи машини, створені для моделювання аналітичних дій, що здійснюються людським мозком.

Нейронні мережі відносяться до напрямку штучного інтелекту (ШІ) і застосовуються для розпізнавання прихованих закономірностей у необроблених даних, угруповання та класифікації, а також розв’язання завдань у галузі ШІ, машинного та глибокого навчання.

Штучні нейронні мережі складаються з кількох шарів (рисунок 1):

- вхідний;
- прихований;
- вихідний.




Рисунок 1 – Схема шарів нейронної мережі

У кожному з них є кілька вузлів, які з'єднані з усіма вузлами в мережі за допомогою різних зв'язків і мають свою «вагу», що впливає на силу сигналу, що передається.

Така архітектура дозволяє вести паралельну обробку даних і постійно порівнювати їх із результатами обробки на кожному з етапів.

Нейронні мережі спочатку навчаються на розмічених наборах даних з очевидними закономірностями, а потім використовують отримані навички для самонавчання та досягнення результату.

При цьому нейромережа може здійснювати мільйони спроб для досягнення таких же результатів, як і приклад, наданий для навчання.

1.2. Види нейронних мереж

Є десятки видів нейромереж, які відрізняються архітектурою, особливостями функціонування та сферами застосування. При цьому найчастіше зустрічаються мережі трьох видів:

- нейронні мережі прямого поширення (**Feed forward neural networks, FFNN**);

Це прямолінійний вид нейромереж, у якому сусідні вузли шару пов'язані, а передача інформації здійснюється безпосередньо від вхідного шару до вихідного. FFNN мають малу функціональність, тому часто використовуються у комбінації із мережами інших видів.

- згорткові нейронні мережі (**Convolutional neural network, CNN**);

Складаються з п'яти типів: вхідного, згорткового, об'єднуючого, підключеного та вихідного.

Кожен шар виконує певне завдання: узагальнює чи з'єднує дані.

Згорткові нейромережі застосовуються для класифікації зображень, розпізнавання об'єктів, прогнозування, обробки природної мови та інших завдань.

- Рекурентні нейронні мережі (**Recurrent Neural Network, RNN**);

Використовують спрямовану послідовність зв'язку між вузлами. У RNN результат обчислень на кожному етапі використовується як вихідні дані для

наступного. Завдяки цьому рекурентні нейронні мережі можуть обробляти серії подій у часі або послідовності для отримання результату обчислень.

RNN застосовують для мовного моделювання та генерації текстів, машинного перекладу, розпізнавання мовлення та інших завдань.

1.3. Типи завдань, які можуть вирішуватись нейронною мережею

Виділяють кілька базових типів завдань, на вирішення яких можна використовувати нейромережі.

- **класифікація;**

Для розпізнавання обличь, емоцій, типів об'єктів: наприклад, квадратів, кіл, трикутників. Також для розпізнавання образів, тобто вибору конкретного об'єкта із запропонованої множини: наприклад, вибір квадрата серед трикутників.

- **регресія;**

Для визначення віку за фотографією, складання прогнозу біржових курсів, оцінки вартості майна та інших завдань, що вимагають отримання в результаті обробки конкретного числа.

- **прогнозування часових рядів;**

Для складання довгострокових прогнозів з урахуванням динамічного часового низки значень. Наприклад, нейромережі застосовуються для прогнозування цін, фізичних явищ, обсягу споживання та інших показників. По суті навіть роботу автопілота Tesla можна віднести до процесу прогнозування часових рядів.

- **кластеризація;**

Для вивчення та сортування великого обсягу нерозмічених даних за умов, коли невідомо кількість класів на виході, тобто для об'єднання даних за ознаками. Наприклад, кластеризація застосовується виявлення класів картинок і сегментації клієнтів.

– генерація.

Для автоматизованого створення контенту чи його трансформації. Генерація за допомогою нейромереж застосовується для створення унікальних текстів, аудіофайлів, відео, розфарбовування чорно-білих фільмів та навіть зміни навколишнього середовища на фото.

1.4. Призначення штучних нейронних мереж при прогнозуванні погодних явищ в реальному житті

Для прогнозування погодних явищ частіше всього використовують рекурентні нейронні мережі, згорткові нейронні мережі і багат шаровий перцептрон. Це підтверджує тематична література.

Стаття Jung Min Han, Yu Qian Ang, Ali Malkawi, Holly W. Samuelson «Using recurrent neural networks for localized weather prediction with combined use of public airport data and onsite measurements» [14] пропонується використання рекурентних нейронних мереж для створення синтетичних локалізованих даних про погоду, які є значно більш точними та репрезентативними для місцевих умов, ніж стандартні погодні файли. Прогнози були підтверджені фактичними вимірами на місці, і була досягнута низька середньоквадратична помилка прогнозу температури 2,96 та підвищення точності перевірки більш ніж 185%. Загалом продуктивність обраних моделей показала більш ніж 100-відсоткове підвищення точності випробувань порівняно з стандартними файлами погоди та даними метеостанцій у найближчому аеропорту.

У цьому дослідженні [14] аналізується використання Recurrent Neural Network (RNN) для моделювання характеристик будівлі та пропонується методологія для створення високоточних локалізованих прогнозів погоди, які підходять для наступних 22 додатків моделювання характеристик будівлі, таких як моделювання енергоспоживання. У дослідженні також порівнюється ефективність традиційних підходів Feed Forward Neural Network (FFNN) з

варіантами RNN, перевіреними на основі даних, виміряних вдома. Для цього дослідження повні набори річних погодинних профілів температури з 8760 точками даних було отримано з національної бази даних сонячного випромінювання.

Окремий набір даних про погоду зібрано на метеостанції Harvard HouseZero. Цей набір даних про погоду є додатковим незалежним набором тестів для подальшої перевірки достовірності та точності моделі. Це підмножина даних використовується для навчання нейронної мережі, тобто підібрані моделі штучних нейронних мереж будуть навчатися на даних про погоду з січня по червень, а потім моделі будуть використовуватись для створення прогнозів на липень-грудень. Для перевірки та тестування ці прогнози будуть порівнюватися з фактичними даними вимірювань на місці, щоб розрахувати підвищення точності в порівнянні з базовими даними з аеропорту.

Стаття Lemuel Clark P. Velasco, Ruth P. Serquiña, Mohammad Shahin A. Abdul Zamad, Bryan F. Juanico, Junneil C. Lomocso «Bik-ahead Rainfall Forecasting Using Multilayer Perceptron Neural Network» [15] представлена реалізація прогнозу опадів на тиждень вперед, у якому для обробки історичних даних про опади використовується модель багат шарового персептрону (MLP). Належна підготовка даних, реалізація моделі та оцінка ефективності були проведені для двох моделей MLP, які дають багатообіцяючі результати у прогнозуванні опадів на тиждень наперед. Модель багат шарового персептрона, що має вхідний шар, прихований шар та вихідний шар, була реалізована у системі прогнозування опадів.

У статті A. J. Litta, Sumam Mary Idicula, U. C. Mohanty «Artificial Neural Network Model in Prediction of Meteorological Parameters під час Premonsoon Thunderstorms» [16] проводяться експерименти з моделлю штучної нейронної мережі для прогнозування сильні грози, з використанням метеорологічних параметрів, на які впливає гроза.

Оцінюється продуктивність шести алгоритмів навчання, а саме: Step (STP), Momentum (MOM), Conjugate Gradient (CG), Quick Propagation (QKP), Levenberg-Marquardt (LM) та Delta-Bar-Delta (DBD). Точність прогнозів оцінювалася за коефіцієнтом кореляції (CC), середньоквадратичної помилки (RMSE), середньої абсолютної помилки (MSE) та відсотку правильності (PC) між виміряними та прогнозованими значеннями.

Метеорологічні дані, а саме погодинний середній тиск на рівні моря, відносна вологість та швидкість вітру за 3 роки (квітень та травень з 2007 по 2009 рр.), зібрані Індійським метеорологічним департаментом (IMD) Калькутти, використовувалися як вхідні дані для навчання та тестування моделі штучної нейронної мережі, яка використовуватиметься для прогнозування погодинної температури.

Дані про погоду, а саме погодинний середній тиск на рівні моря, температура та швидкість вітру за 3 роки (квітень та травень з 2007 по 2009 рік) у Калькутті, використовувалися як вхідні дані для навчання та тестування моделі, яка використовуватиметься для прогнозу погодинної відносної вологості. Найбільша кількість гроз буває над Калькуттою у квітні та травні. Таким чином, для навчання та тестування вибираються погодинні набори цих двох місяців. Іншими додатковими вхідними параметрами для кожної моделі є місяць, день та година спостереження.

У статті Shahab Wahhab Kareem, Zhala Jameel Hamad, Shavan Askar «An evaluation of CNN і ANN в попередньому прогнозі погодження: A review» [17] було обрано дві архітектури нейронних мереж для використання як моделі прогнозування погоди. Перша модель – це Long-Short Term Memory (LSTM), яка є рекурентною нейронною мережею (RNN). Мережі LSTM підходять для різної обробки, класифікації та прогнозування відповідно до інформації про тимчасові ряди.

Модель LSTM використовувалася для прогнозування швидкості вітру на кожен день показала, що вона добре працює навіть за умов несподіваних змін погоди.

2. ДОСЛІДЖЕННЯ ТЕХНОЛОГІЙ ЗАСТОСУВАННЯ НЕЙРОМЕРЕЖ ТА МЕТОДІВ ЇХ НАВЧАННЯ

2.1. Класифікація нейронних мереж

Класифікація нейронних мереж за характером навчання ділиться на ті, що:

- використовують навчання з вчителем;
- використовують навчання без вчителя;

1) Навчання з вчителем припускає, що для кожного вхідного вектору існує цільовий вектор, що представляє собою потрібний вихід. Разом вони називаються навчальною парою. Зазвичай мережа навчається на деякому числі таких навчальних пар. Представляється вихідний вектор, вираховується вихід мережі і порівнюється з відповідним цільовим вектором. Далі ваги змінюються у відповідності з алгоритмом, який спрямований на мінімізацію помилки. Вектори навчальної множини представляються послідовно, вираховуються помилки і ваги підлаштовуються для кожного вектору до тих пір, поки помилки по всьому навчальному масиву не досягнуть допустимого рівня.

2) Навчання без вчителя являє собою більш правдоподібну модель навчання з точки зору біологічних коренів штучних нейромереж. Розвинута Кохоненом і багатьма іншими, вона не потребує цільового вектора для виходу і, відповідно, не потребує порівняння з зумовленими ідеальними відповідями.

Навчальна множина складається з вхідних векторів. Навчальний алгоритм підлаштовує ваги так, щоб в результаті були узгоджені вихідні вектори, тобто щоб пред'явлення достатньо близьких вхідних векторів давало однакові виходи. Процес навчання, отже, виділяє статистичні властивості навчальної множини і групує схожі вектори в класи.

За типом налаштування вагів нейромережі діляться на:

- мережі з фіксованими зв'язками – вагові коефіцієнти нейронної мережі обираються зразу, виходячи з умов задачі;
- мережі з динамічними зв'язками – для них в процесі навчання відбувається налаштування синаптичних вагів.

Класифікація нейронних мереж за типом вхідної інформації ділиться на:

- аналогові – вхідна інформація представлена в формі дійсних чисел;
- двійкові – вся вхідна інформація в таких мережах представляється в виді нулів і одиниць.
-

2.2. Архітектура нейронних мереж

У повнозв'язкових нейронних мережах кожен нейрон передає свій вихідний сигнал іншим нейронам, у тому числі й самому собі. Всі вхідні сигнали подаються всім нейронам. Вихідними сигналами мережі можуть бути всі або деякі вихідні сигнали нейронів після кількох тактів функціонування мережі.

У багат шарових (шарових) нейронних мережах нейрони об'єднуються в шари. Шар містить сукупність нейронів із єдиними вхідними сигналами. Число нейронів у шарі може бути будь-яким і не залежить від кількості нейронів в інших шарах. У загальному випадку мережа складається з шарів, пронумерованих зліва направо. Зовнішні вхідні сигнали подаються на входи нейронів шару (його часто нумерують як нульовий), а виходами мережі є вихідні сигнали останнього шару. Крім вхідного та вихідного шарів у багат шаровий нейронної мережі є один або кілька прихованих шарів. Зв'язки від виходів нейронів деякого шару q до входів нейронів наступного шару $(q+1)$ називаються послідовними.

2.3. Поняття персептрону

Персептрон – це нейронна мережа, яка є алгоритмом для виконання двійкової класифікації. Він визначає, чи належить об'єкт до певної категорії (наприклад, чи є тварина на малюнку кішкою чи ні).

Персептрон займає особливе місце в історії нейронних мереж та штучного інтелекту, тому що початкові ілюзії щодо його ефективності призвели до появи т.з. спростування Мінського-Паперта і застою досліджень нейронних мереж, які тривали кілька десятиліть. Лід рушив після публікації робіт Джеффа Хінтона в 2000-х роках, результати якого перетворили всі галузі машинного навчання.

Френк Розенблатт, родоначальник персептрона, популяризував його як пристрій, а не алгоритм. Персептрон увійшов у світ як апаратне забезпечення, Розенблатт психолог, який навчався, а потім читав лекції у Корнельському університеті, отримав фінансування від Управління з морських досліджень у США, щоб сконструювати машину, яка могла б навчатись.

Персептрон є лінійним класифікатором, тобто алгоритмом, який класифікує об'єкт шляхом поділу двох категорій прямої. Об'єктом зазвичай є вектор-функція x взята з вагою w і зміщена на b : $y = w * x + b$.

На виході персептрон видає результат y , заснований на кількох речових вхідних об'єктах шляхом формування лінійної комбінації з використанням вагових коефіцієнтів (іноді з наступним пропусканням результату через нелінійну функцію активації).

2.3.1. Одношаровий персептрон.

Його апаратний алгоритм не включав кілька рівнів, які дозволяють нейронним мережам моделювати ієрархію ознак. Це була дрібна нейронна мережа, яка заважала персептрону виконувати нелінійну класифікацію, наприклад, обчислювати значення функції XOR (тригером оператора XOR є

розбіжність двох об'єктів, інша назва – «що виключає чи»), як показали Мінський та Паперт у своїй книзі (рисунок 2).




Рисунок 2 - Схема одношарового персептрона

2.3.2. Багатошаровий персептрон

Подальше дослідження багатошарових персептронів показало, що вони здатні апроксимувати як оператор XOR, так і багато інших нелінійних функцій.

Так само, як Розенблатт заснував персептрон на нейроні Маккаллоха-Пітса, розробленому в 1943 році, так і самі персептрони є будівельними блоками, які можуть бути корисні тільки в таких великих функціях, як багатошарові персептрони.

Багатошаровий персептрон є глибокою штучною нейронною мережею, що включає в себе кілька персептронів. Багатошарові персептрони складаються з вхідного шару для прийому сигналу, вихідного шару, який приймає рішення або робить пророцтво про вхідний об'єкт, а між ними – довільна кількість прихованих шарів, які є справжнім обчислювальним двигуном. Багатошарові персептрони з одним прихованим шаром здатні апроксимувати будь-яку безперервну функцію.

2.4. Як працює персептрон?

Застосовуються для вирішення контрольованих завдань навчання: вони тренуються за набором пар вхідних/вихідних об'єктів і навчаються моделювати кореляції (тобто залежність) між цими даними. Навчання включає

налаштування параметрів моделі (вагових коефіцієнтів, зсувів) для мінімізації похибки. Для коригування цих параметрів щодо похибки використовується алгоритм зворотного розповсюдження, а сама похибка може бути обчислена різними способами, зокрема шляхом обчислення середньоквадратичного відхилення (RMSE).

Мережі прямого поширення, такі як багат шаровий персептрон, здебільшого складаються з двох видів рухів: вперед і назад.

При кроці вперед потік сигналу переміщається від вхідного шару через приховані до вихідного, а рішення, отримане на вихідному шарі, порівнюється з апріорно відомою правильною відповіддю.

При кроці назад з використанням правила диференціювання складних функцій через персептрон у зворотному напрямку поширюються приватні похідні функції, похибки за ваговими коефіцієнтами та зсувами. Даний акт диференціювання дає градієнт похибки, з допомогою якого можуть бути скориговані параметри моделі, оскільки вони наближають БП однією крок ближче до мінімуму похибки.

В мережі Інтернет можна знайти достатньо теорії щодо створення нейромереж для регулювання процесом або системою, проте готові рішення знайти дуже важко. Більшість нейромереж, призначених для керування або визначення параметрів автоматичних регуляторів розробляються для конкретних задач і знаходяться у закритому доступі.

Для створення ШНМ використовуються різноманітні програмні системи, проте всі вони мають певні обмеження – неможливість створити окремий нейромережевий модуль, мають у своєму складі надлишкові типології нейромереж, не дають можливості запровадити власну сумуючу функцію, мають обмежений набір активаційних функцій, тощо. Розглянемо деякі з таких систем.

Neuroph – система для нейромережевого розпізнавання, яка написана на Java (рисунок 3). Складається з JAVA API, яка включає в себе основні класи, класи-утиліти і реалізацію конкретних типів нейронних мереж. Також включає в себе середовище *Neuroph Studio*, реалізовану на платформі *NetBeans*.




Рисунок 3 - Интерфейс програми Neuroph

У середовищі реалізовані наступні нейромережі архітектури:

- адалайн;
- персептрон;
- багатoshаровий персептрон з алгоритмом зворотного поширення помилки, моментом;
- мережа Хопфілда;
- двостороння асоціативна пам'ять;
- мережа Кохонена;
- RBF нейронна мережа.

В систему включені приклади використання мереж для прогнозування цін на фінансових ринках, приклади класифікації тварин і інші. Програмний пакет доволі складний та має багато надлишкової інформації. Окрім того, він великий за розміром, оскільки включає в себе модулі для створення різних типів нейромереж і не може бути використаний як окремий модуль.

Simbrain – це безкоштовний інструмент для створення, запуску та аналізу нейронних мереж (комп'ютерне моделювання схем мозку). Simbrain прагне бути максимально наочним і простим у використанні. Унікальні особливості Simbrain включають його інтегровані «компоненти світу» та його здатність представляти простір стану мережі. Він написаний на Java і працює на Windows, Mac OS X і Linux (Рис. 4).




Рисунок 4 - Інтерфейс програми Simbrain

В системі реалізовано велику кількість різних варіантів нейронів і типів мереж, присутнє навчання без учителя. Створення та редагування нейронних

мереж в середовищі Simbrain відбувається візуально. У разі візуального побудови, користувач може бачити процес зміни ваг в мережі, передачі сигналу. Можливо відстежувати і алгоритм зворотного поширення помилки. Але користувач також може скористатися Java API для конструювання власних завдань і додавання необхідних технологій в систему. Введення вибірок в мережу здійснюється вручну, що не завжди зручно. Ця система більше призначена для навчання, аніж для створення працюючого модуля. Складнощі з введенням навчальних даних, а також надлишковий розмір програми через наявність бібліотек для візуалізації роблять програму непідходящою для вирішення поставленої задачі.

Deep Learning Toolbox (раніше *Neural Network Toolbox*) забезпечує основу для проектування і реалізації глибокої нейронної мережі, використовуючи як попередньо навчені моделі, так і додатки разом з інструментами для проектування розробки архітектур нейронних мереж (рисунок 5).




Рисунок 5 - Інтерфейс модуля Deep Learning Toolbox

Пакет забезпечує всебічну підтримку типових нейромережових парадигм і має відкриту модульну архітектуру. Пакет містить функції командного рядка і графічний інтерфейс користувача для швидкого покрокового створення нейромереж. Крім цього Deep Learning Toolbox забезпечує підтримку Simulink, що дозволяє моделювати нейромережі і створювати блоки на основі розроблених нейромережових структур.

Ключові характеристики модуля:

- графічний інтерфейс користувача для покрокового створення, навчання і імітаційного моделювання нейронних мереж;
- підтримка найбільш поширених керованих і некерованих мережових структур;
- повний перелік навчальних і тестуючих функцій;
- динамічні алгоритми навчання мереж, що включають тимчасову затримку, нелінійну авторегресію, ланцюгові і настроюються динамічні структури;
- блоки Simulink для створення нейронних мереж і розвинених блоків для систем контролю;
- автоматична генерація блоків Simulink з об'єктів нейронної мережі;
- модульне подання мережі, що дозволяє створювати необмежену кількість вхідних шарів і об'єднаних мереж, а також графічне представлення архітектури мережі;
- функції попередньої і постобробки, блоки Simulink для поліпшення процесу навчання і оцінки продуктивності мережі;
- візуалізація топології і процесу навчання нейронної мережі.

Encog – система Encog є найбільш повною з розглянутих (рисунк 6). Вона включає в себе велику кількість ефективно написаних Java класів. В ній реалізовані не тільки нейромережові алгоритми розпізнавання, але і

кластеризація, генетичні алгоритми, приховані марковські моделі, байєсовські мережі та ін.




Рисунок 6 - Інтерфейс системи Encog

Підтримувані архітектури нейронних мереж:

- адалайн;
- машина Больцмана;
- нейронні мережі зворотного поширення;
- рекурентні мережі Ельмана;
- рекурентні мережі Джордана;
- самоорганізуються карти Кохонена і т.д.

Функції активації нейронів:

- біполярна;
- змагальна;
- функція Еліотта;

- функція Гаусса;
- гіперболічний тангенс;
- лінійна;
- синусоїдальна;
- сігмоїда.

У порівнянні з іншими, система Encog написана дуже ефективно, підтримується паралельне функціонування мереж на машинах з декількома процесорами.

Усі перераховані реалізації мають багато доступних функції нейромереж, проте не дозволяють додавати нові архітектури мереж, змінювати характеристики навчання, оптимізувати структуру мережі.

3. РОЗРОБКА ТА НАВЧАННЯ НЕЙРОННОЇ МЕРЕЖІ ДЛЯ ПРОГНОЗУВАННЯ НЕБЕЗПЕЧНИХ ПОГОДНИХ ЯВИЩ

3.1. Вибір програмного забезпечення

Згідно вивченої інформації про програмне забезпечення, яка була подана у останньому підрозділі, для визначення показників погодних умов було обрано Neuroph Studio.

3.2. Збір даних та їх коригування

Для управління ризиками необхідно їх спрогнозувати. Для рішення задач прогнозування потрібні моделі, які описуються зміною стану управляючої системи в перспективі і базоване на вивченні її минулої поведінки. За допомогою методики прогнозування, яка базується на закономірностях формування подій, прогнозують вид та місце виникнення небезпечного погодного явища.

Для вирішення задач за допомогою нейромереж потрібно зібрати дані для її навчання. Набір даних для навчання представляє собою набір результатів спостережень, для яких вказані вхідні та вихідні змінні.

Як показують сучасні дослідження, процеси формування небезпечних явищ супроводжуються фізичними ефектами, які локально проявляються в різних земних точках – це провісники подій. За характеристиками цих факторів можна судити про величину ймовірності появи певних погодних явищ. Оскільки предметом дослідження є небезпечні погодні умови, то варто відмітити коротеньку інформацію про кожну:

- сильні вітри – це приземлений вітер зі швидкістю більше ніж 15 м/с;
- завірюха – це переміщення сніжних мас над поверхнею землі поривчастим і сильним вітром, швидкість якого не менше 15 м/с при видимості менше 500 м;
- сильні дощі – це рясні опади з інтенсивністю більше ніж 30 мм за добу;

- град – тверді опади в діаметрі від 5 до 20 мм;
- шквали – горизонтальні вири при швидкості вітру більше 15 м/с;
- паморозь – відкладення води і льоду на поверхні при діаметрі не менше 50 мм.

3.3. Формування навчальної вибірки багатошарового персептрона

Головним компонентом для успішної роботи нейромережі є кодування вхідних і вихідних даних.

Нейронні мережі працюють лише з числовими вхідними даними, відповідно до цього, необроблені дані треба перетворити. В моєму випадку вхідними даними для багатошарового персептрона будуть:

- температура повітря;
- його вологість;
- швидкість вітру та атмосферний тиск.

Кодуємо ці дані і для кращої наглядності представлю їх у виді таблиць 1, 2, 3 і 4 відповідно.

Максимальне значення при кодуванні температури (табл. 1) 0,9, мінімальне – 0,01.

Таблиця 1 – Кодування показників температури

Температура, С	Кодування
від -20	0,9
від -15 до -20	0,8
від -10 до -15	0,7
від -5 до -10	0,6
від 0 до -5	0,5
від +5 до 0	0,4

від +10 до +5	0,3
від +15 до +10	0,2
від +20 до +15	0,1
від +25 до +20	0,01

Максимальне значення при кодуванні швидкості вітру (табл. 2) 0,9, мінімальне – 0.01.

Таблиця 2 – Кодування показників швидкості вітру

Швидкість вітру, м/с	Кодування
від 4,2	0,9
від 4 до 4.2	0,85
від 3.8 до 4	0,8
від 3.6 до 3,8	0,75
від 3.4 до 3,6	0,7
від 3.2 до 3,4	0,6
від 3 до 3.2	0,55
від 2.8 до 3	0,5
від 2.6 до 2.8	0,45
від 2.4 до 2.6	0,4
від 2.2 до 2.4	0,35
від 2 до 2.2	0,3
від 1.8 до 2	0,25
від 1.6 до 1.8	0,2
від 1.4 до 1.6	0,15
від 1.2 до 1.4	0,1
від 1 до 1.2	0,01

Максимальне значення при кодуванні вологості повітря (табл. 3) 1, мінімальне – 0.01.

Таблиця 3 – Кодування показників вологості повітря

Вологість, %	Кодування
100	1
від 90 до 100	0,9
від 80 до 90	0,8
Вологість, %	Кодування
від 70 до 80	0,7
від 60 до 70	0,6
від 50 до 60	0,5
від 40 до 50	0,4
від 30 до 40	0,3
від 20 до 30	0,2
від 10 до 20	0,1
від 0 до 10	0,01

Для утворення певних небезпечних погодних явищ нормальний тиск (760 мм. рт.ст.) є непідходящим, тому максимальне значення при кодуванні тиску (табл. 4) 0.9 присвоюю значенню, що є нижчим за 760 мм. рт.ст., мінімальне – 0.1.

Таблиця 4 – Кодування показників атмосферного тиску

Атмосферний тиск, мм рт.ст	Кодування
Нормальне 760	0,1
Вище 760	0,5
Нижче 760	0,9

Аналогічним чином представлю кодування вихідних даних для багат шарового персептрона.

Максимальне значення при кодуванні сильного вітру (табл. 5) 0,9, мінімальне – 0.01.

Таблиця 5 – Кодування показників сильного вітру

Сильний вітер, м/с	Кодування
-20	0,9
-15	0,8
-10	0,7
Сильний вітер, м/с	Кодування
-5	0,6
0	0,5
+5	0,4
+10	0,3
+15	0,2
+20	0,1
+25	0,01

Максимальне значення при кодуванні завірюхи (висоти снігового покриву) (табл. 6) 1, мінімальне – 0.01.

Таблиця 6 - Кодування показників завірюхи (сніжного покриву)

Завірюха (висота сніжного покриву)	Кодування
від 100 см	1
від 90 см до 100 см	0,9
від 80 см до 90 см	0,8

від 70 см до 80 см	0,7
від 60 см до 70 см	0,6
від 50 см до 60 см	0,5
від 40 см до 50 см	0,4
від 30 см до 40 см	0,3
від 20 см до 30 см	0,2
від 10 см до 20 см	0,1
від 0 см до 10 см	0.01

Під час кодування значень граду (табл. 7) було використано також ймовірність його появи в конкретний місяць. До прикладу, взимку вона буде нижчою чим влітку.

Максимальне значення при кодуванні вологості повітря (таблиця 7) 1, мінімальне – 0.01.

Таблиця 7 – Кодування показників граду

Град (ймовірність появи), %	Кодування
100%	1
від 90 до 100	0,9
від 80 до 90	0,8
від 70 до 80	0,7
від 60 до 70	0,6
від 50 до 60	0,5
від 40 до 50	0,4
від 30 до 40	0,3
від 20 до 30	0,2
від 10 до 20	0,1
від 0 до 10	0.01

Під час кодування значень шквалів (табл. 8) було використано також ймовірність їх появи в конкретний місяць. До прикладу, взимку вона буде нижчою чим влітку та восени.

Максимальне значення при кодуванні шквалів (таблиця 8) 1, мінімальне – 0.01.

Таблиця 8 – Кодування показників шквалів

Шквали (ймовірність появи), %	Кодування
100	1
від 90 до 100	0,9
від 80 до 90	0,8
Шквали (ймовірність появи), %	Кодування
від 70 до 80	0,7
від 60 до 70	0,6
від 50 до 60	0,5
від 40 до 50	0,4
від 30 до 40	0,3
від 20 до 30	0,2
від 10 до 20	0,1
від 0 до 10	0.01

Під час кодування значень заморозків (табл. 9) було використано також ймовірність їх появи в конкретний місяць. До прикладу, в березні, квітні, серпні, вересні та жовтні буде ймовірність більша, ніж в інші місяці року.

Максимальне значення при кодуванні заморозків (табл. 9) 1, мінімальне – 0.01.

Таблиця 9 – Кодування показників заморозків

Заморозки (ймовірність появи), %	Кодування
100%	1
від 90 до 100	0,9
від 80 до 90	0,8
від 70 до 80	0,7
від 60 до 70	0,6
від 50 до 60	0,5
від 40 до 50	0,4
від 30 до 40	0,3
від 20 до 30	0,2
від 10 до 20	0,1
від 0 до 10	0.01

Під час кодування значень сильного дощу було прийнято до уваги значення опадів згідно даних сайту статистики погоди Meteorpost (табл. 10).

Таблиця 10 – Кодування показників сильного дощу

Сильний дощ, мм	Кодування
від 100 мм	1
від 90 мм до 100 мм	0,9
від 80 мм до 90 мм	0,8
від 70 мм до 80 мм	0,7
від 60 мм до 70 мм	0,6
від 50 мм до 60 мм	0,5
від 40 мм до 50 мм	0,4
від 30 мм до 40 мм	0,3
від 20 мм до 30 мм	0,2
від 10 мм до 20 мм	0,1
від 0 мм до 10 мм	0.01

Далі формую вибірку згідно вищезазначеного кодування вхідних та вихідних показників. В даній сфері не є актуальним аналіз на основі великої кількості даних, тому використаю статистику за 2021й рік (табл. 11) в нашому регіоні.

Таблиця 11 – дані за 2021-й рік з врахуванням кодування

	Січень	Лютий	Березень	Квітень	Травень	Червень	Липень	Серпень	Вересень	Жовтень	Листопад	Грудень
Температура	0.6	0.5	0.5	0.5	0.3	0.1	0.01	0.01	0.01	0.1	0.3	0.4
Швидкість вітру	0.45	0.4	0.7	0.5	0.35	0.35	0.45	0.35	0.45	0.4	0.55	0.7
Вологість	0.5	0.4	0.8	0.6	0.8	0.6	0.5	0.6	0.8	0.8	0.5	0.5
Атмосферний тиск	0.5	0.1	0.9	0.1	0.5	0.9	0.9	0.9	0.1	0.9	0.9	0.9
Сильний вітер	0.4	0.6	0.6	0.3	0.7	0.6	0.5	0.4	0.6	0.5	0.5	0.5
Завірюха	0.3	0.5	0.6	0.4	0.01	0.01	0.01	0.01	0.01	0.01	0.01	0.01
Град	0.2	0.4	0.2	0.6	0.3	0.5	0.6	0.5	0.6	0.1	0.01	0.01
Шквали	0.4	0.5	0.6	0.5	0.8	0.3	0.7	0.4	0.5	0.5	0.7	0.6
Заморозки	0.01	0.01	0.01	0.4	0.6	0.01	0.01	0.01	0.3	0.6	0.7	0.8
Сильний дощ	0.6	0.8	1	0.3	0.4	0.9	0.2	0.5	1	0.1	0.8	0.2

3.4. Схема нейромережі в Neuroph Studio

Згідно інформації, яка була представлена у попередньому підрозділі, можна розпочати реалізацію завдання.

Логічно, що багатошаровий персептрон може складатись з довільної кількості шарів нейронів. Кількість нейронів також може бути довільною. Зазвичай, у всіх прихованих шарах однакова кількість нейронів.

Для того, щоб покращити швидкодію нейромережі, використовуватиму багатошаровий персептрон, який складається з двох внутрішніх шарів (рис. 7).




Рисунок 7 – Структура мережі прогнозування погоди

Кількість входів персептрона має співпадати з кількістю вхідних параметрів для навчання, у моєму випадку їх чотири, кількість виходів буде рівнятися числу небезпечних явищ природи, тобто шести.

Якщо в мережі мало прихованих нейронів або шарів – мережа не навчиться і помилка в роботі мережі буде залишатись великою. Якщо нейронів чи шарів забагато – швидкодія буде низькою, а пам'яті комп'ютера потрібно буде дуже багато.

Згідно того, що в мережу подаються значення як вхідних, так і вихідних сигналів, навчання буде з вчителем, а ваги синоптичних зв'язків будуть коригуватись по внутрішньому алгоритму.

Якби було навчання без вчителя, то виходи нейронної мережі формувались би самостійно, а ваги змінюватись би згідно алгоритму, який враховує вхідні і похідні від них сигнали.

Навчання з вчителем виконується за допомогою алгоритму зворотнього розповсюдження помилки. Цей алгоритм базується на корекції помилок. При його виконанні є два проходи, які виконуються в процесі розрахунків. Перший називають прямим, другий – зворотнім. В прямому проході синаптичні ваги залишаються незмінними у всій мережі, а функціональні сигнали вираховуються послідовно, від нейрона до нейрона.

3.5. Реалізація навчання нейромережі

Згідно показників погоди за останні 10 років, у Києві та області відчутних змін не відбувається, оскільки нема екстремальних стрибків температури, атмосферного тиску та швидкості вітру. Проте ніколи не виключається ймовірність раптової появи небезпечних погодних явищ.

На рисунку 8 представлено результат загального навчання нейромережі, на основі якого буде проводитись розрахунок ймовірності появи тих чи інших явищ, дані про які були внесені у навчальну вибірку.




Рисунок 8 – Результат загального тренування нейромережі

Розрахунок загальної помилки нейромережі:

За допомогою MSE вирахуємо загальну помилку нейромережі

$$\sigma = \sqrt{MSEn/(n-1)}$$

в формулі, n – число виходів нейромережі, яке дорівнює 6.

$$\sigma = \sqrt{0,00408 * 6/5} = 0,06997 = 6.997 \%$$

Для того, щоб дізнатись успішність роботи нейромережі, подамо на вхід перший набір з навчальної вибірки. Успішним вважається, коли відносна достовірність розпізнавання не менше 80%. Виходячи з отриманих результатів, можна зробити висновок, що якість навчання є високою, оскільки достовірність розпізнавання складає 89%. Для наглядності занесемо дані в таблицю 12.

Таблиця 12 – Результати на основі даних з навчальної вибірки

Набір з навчальної вибірки	0,4	0,1	0,01	0,2	0,1	0,6
Отриманий набір	0,428	0,058	0,031	0,271	0,2	0,514

3.6. Розрахунок ймовірності на значеннях, які не є в навчальній вибірці

Далі оберемо рандомно значення, яких нема у навчальному наборі для того, щоб спрогнозувати ймовірну появу певних опадів

Перший набір – температура 0.4, швидкість вітру 0.7, вологість 0.5 та атмосферний тиск 0.5.

Другий набір – температура 0.3, швидкість вітру 0.15, вологість 0.7 та атмосферний тиск 0.9.

Третій набір – температура 0.7, швидкість вітру 0.7, вологість 0.5 та атмосферний тиск 0.1.

Почергово кожен з наборів протестуємо на нашій нейромережі і відповідно отримуємо результати (табл. 13).

Таблиця 13 – Результати навчання за трьома довільними наборами

Показники	1	2	3
Температура	0.4	0.3	0.7
Швидкість вітру	0.7	0.15	0.7
Вологість	0.5	0.7	0.5
Тиск	0.5	0.9	0.1
Сильний вітер	0.437	0.529	0.411
Завірюха	0.134	0.043	0.058
Град	0.005	0.306	0.021
Шквали	0.321	0.539	0.24
Заморозки	0.036	0.315	0.185
Сильний дощ	0.504	0.384	0.522

Проаналізувавши отримані результати можна побачити, що:

- при показниках 1 є ймовірність сильного дощу зі шквалами та сильним вітром;

- при показниках 2 є ймовірність сильного вітру та шквалів;
- при показниках 3 є ймовірність сильного дощу та вітру.
-

3.7. Порівняння прогнозування на прикладі з м. Оклахома

Для порівняння зробимо статистичну вибірку даних з міста Оклахома. Це є найбільше місто штату Оклахома і є адміністративним центром округу Оклахома, де щороку відбувається велика кількість небезпечних явищ, в тому числі і торнадо. Оклахома є третьою за частотою їх появи.

Кодування всіх таблиць з вхідними та вихідними даними лишаю таким самим, окрім таблиці з даними швидкості вітру.

Максимальне значення при кодуванні швидкості вітру в Оклахома 0.9, мінімальне – 0.01 (табл. 14).

Таблиця 14 – Коригування показників температури

Швидкість вітру, м/с	Кодування
6,2	0,9
6	0,85
5,8	0,8
5,6	0,75
5,4	0,7
5,2	0,6
5	0,55
4,8	0,5
4,6	0,45
4,4	0,4
4,2	0,35
4	0,3

Швидкість вітру, м/с	Кодування
3,8	0,25
3,6	0,2
3,4	0,15
3,2	0,1
3	0,01

Схема нейронної мережі погоди буде виглядати так само (рис. 9).




Рисунок 9 – Схема нейромережі для прогнозування погоди в м. Оклахома

Для коректного навчання використовуємо дані лише за 2021 рік (табл. 15).

Таблиця 15 – Дані погоди м. Оклахома за 2021 рік

	Січ ень	Лют ий	Берез ень	Квіт ень	Трав ень	Черв ень	Липе нь	Серп ень	Верес ень	Жовт ень	Листо пад	Груд ень
Темпера тура	0.4	0.5	0.2	0.1	0.1	0.01	0.01	0.01	0.01	0.01	0.2	0.2
Швидкіс ть вітру	0.55	0.75	0.9	0.85	0.55	0.3	0.2	0.35	0.4	0.55	0.55	0.5
Вологіст ь	0.7	0.7	0.58	0.59	0.76	0.73	0.7	0.67	0.54	0.63	0.59	0.54
	Січ ень	Лют ий	Берез ень	Квіт ень	Трав ень	Черв ень	Липе нь	Серп ень	Верес ень	Жовт ень	Листо пад	Груд ень
Атмосфе рний тиск	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9
Сильний вітер	0.7	0.8	0.6	0.7	0.6	0.5	0.4	0.6	0.8	0.9	0.7	0.7
Завірюха	0.7	0.6	0.7	0.4	0.2	0.1	0.1	0.1	0.1	0.1	0.5	0.7
Град	0.8	0.7	0.6	0.7	0.5	0.4	0.3	0.3	0.6	0.7	0.6	0.8
Шквали	0.9	0.8	0.7	0.8	0.6	0.4	0.5	0.4	0.6	0.6	0.7	0.6
Заморозк и	0.6	0.7	0.4	0.3	0.2	0.1	0.01	0.01	0.01	0.01	0.1	0.1
Сильний дощ	0.7	0.7	0.6	0.6	0.6	0.8	0.7	0.7	0.5	0.6	0.5	0.5

В результаті загального навчання отримано такі результати – ймовірність сильного вітру – 0.704, завірюхи – 0.484, граду – 0.664, шквалів – 0.715, заморозків – 0.226 та сильного дощу – 0.608.

Уже на даному етапі можна зробити певні висновки, оскільки є досить велика різниця між появою небезпечних явищ у Києві та Оклахомі (рис. 10).

Розрахунок загальної помилки нейромережі:

За допомогою MSE вирахуємо загальну помилку нейромережі

$$\sigma = \sqrt{MSEn/(n-1)}$$

в формулі, n – число виходів нейромережі, яке дорівнює 6.

$$\sigma = \sqrt{0,1237 * 6/5} = 0,0834 = 8,34 \%$$




Рисунок 10 – Результат загального навчання

3.8. Розрахунок ймовірності на значеннях, які не є в навчальній вибірці

Далі оберемо випадково значення, яких нема у навчальному наборі для того, щоб спрогнозувати ймовірну появу певних опадів

Перший набір – температура 0.4, швидкість вітру 0.7, вологість 0.8 та атмосферний тиск 0.9.

Другий набір – температура 0.6, швидкість вітру 0.4, вологість 0.6 та атмосферний тиск 0.9.

Третій набір – температура 0.1, швидкість вітру 0.8, вологість 0.9 та атмосферний тиск 0.9.

Почергово кожен з наборів протестуємо на нашій нейромережі і відповідно отримуємо результати (табл. 16, рис. 12, 13).

Таблиця 16 – Результати навчання за трьома довільними наборами

Показники	1	2	3
Температура	0.4	0.6	0.1
Швидкість вітру	0.7	0.4	0.8
Вологість	0.8	0.6	0.9
Тиск	0.9	0.9	0.9
Сильний вітер	0.736	0.747	0.678
Завірюха	0.685	0.755	0.321
Град	0.747	0.781	0.594
Шквали	0.789	0.817	0.643
Заморозки	0.513	0.651	0.091
Сильний дощ	0.595	0.598	0.613




Рисунок 11 – Результати розрахунків першого набору




Рисунок 12 – Результати розрахунків другого набору




Рисунок 13 – Результати розрахунків третього набору

Проаналізувавши отримані результати можна побачити, що:

- при показниках 1 висока ймовірність сильного вітру, граду та шквалів;
- при показниках 2 є висока ймовірність граду, шквалів і завірюхи;
- при показниках 3 є висока ймовірність сильного вітру з дощем, також можливі шквали.

ВИСНОВКИ

1. В результаті виконання роботи було навчено нейромережу, яка генерує ймовірність появи небезпечних погодних явищ. Проведені дослідження актуальності застосування подібних нейромереж в реальному житті показали, що визначення параметрів за допомогою нейромереж на даний момент є одним з найперспективніших напрямків у вирахуванні ймовірності появи небезпечних погодних явищ.

2. Для навчання нейромережі була обрана програма Neuroph Studio, в якій використано багат шаровий персептрон з двома прихованими шарами, чотирма вхідними параметрами та шістьма вихідними. Проведено кодування даних, які введені у датасет нейронної мережі. Також було проведено загальне навчання нейромережі за даними міста Києва та області, за результатами якого можна зробити висновок, що вона має достатню точність визначення параметрів. Проте, є можливість підвищення точності за рахунок використання більшої кількості нейронів у прихованих шарах та більш різноманітної навчальної вибірки.

3. За результатами тестування створеної нейромережі для міста Оклахома виявлено, що вона має високу точність визначення параметрів. У результаті досліджень можна зробити висновки, що у нашому регіоні ймовірність появи небезпечних явищ значно менша, ніж у американському місті, Оклахома.

СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. Персептрон [Електронний ресурс] – Режим доступу:
<https://ru.wikipedia.org/wiki/%D0%9F%D0%B5%D1%80%D1%86%D0%B5%D0%BF%D1%82%D1%80%D0%BE%D0%BD>
2. Штучний інтелект [Електронний ресурс] – Режим доступу:
https://uk.wikipedia.org/wiki/%D0%A8%D1%82%D1%83%D1%87%D0%BD%D0%B8%D0%B9_%D1%96%D0%BD%D1%82%D0%B5%D0%BB%D0%B5%D0%BA%D1%82
3. Як працюють нейронні мережі? [Електронний ресурс] – Режим доступу:
<http://apeps.kpi.ua/neural-networks/en>
4. Загальні відомості про лінії зв'язку [Електронний ресурс] – Режим доступу: <https://www.znanius.com/3627.html>
5. Нейронна мережа [Електронний ресурс] – Режим доступу:
https://ru.wikipedia.org/wiki/%D0%9D%D0%B5%D0%B9%D1%80%D0%BE%D0%BD%D0%BD%D0%B0%D1%8F_%D1%81%D0%B5%D1%82%D1%8C
6. Андреева Є. С. Концепція ймовірностно-географічного прогнозування небезпечних погодних явищ, 2008.
7. Філіпович Ю. М., Филиппович А. Ю. Системи штучного інтелекту. М.: МГУП, 2009.
8. Схема багатошарового персептрону [Електронний ресурс] – Режим доступу: https://studfile.net/html/2706/1004/html_Vrs4DB9BTv.eJWQ/img-ZRWHMO.png
9. Схема одношарового персептрону [Електронний ресурс] – Режим доступу: <https://neurohive.io/wp-content/uploads/2018/08/Perceptron-xor-570x375.png>
10. Архів погоди [Електронний ресурс] – Режим доступу:
<https://meteopost.com/weather/archive/>

11. Статистика погоди в Оклахома-сіті [Електронний ресурс] – Режим доступу: https://world-weather.ru/pogoda/usa/oklahoma_city/2021/
12. Поява та перспективи розвитку штучного інтелекту [Електронний ресурс] – Режим доступу: [Державний університет телекомунікацій \(dut.edu.ua\)](http://dut.edu.ua)
13. Персептрон [Електронний ресурс] – Режим доступу: <https://neurohive.io/ru/osnovy-data-science/perseptron-rozenblatta-mashina-kotoraja-smogla-obuchatsja/>
14. Han J. M. Using recurrent neural networks for localized weather prediction with combined use of public airport data and on-site measurements / J. M. Han, Y. Q. Ang, A. Malkawi, H. W. Samuelson // Building and Environment. – 2021. – Vol. 192.
15. Velasco L. C. P. Week-ahead Rainfall Forecasting Using Multilayer Perceptron Neural Network / L. C. P. Velasco, R. P. Serquiña, M. S. A. Abdul Zamad [et al.] // Procedia Computer Science. – 2019. – Vol. 161. – P. 386–397.
16. Litta A. J. Artificial Neural Network Model in Prediction of Meteorological Parameters during Premonsoon Thunderstorms / A. J. Litta, Sumam Mary Idicula, U. C. Mohanty // International Journal of Atmospheric Sciences. – 2013.
17. Kareem S. An evaluation of CNN and ANN in prediction weather forecasting: A review / S. Kareem, Z. J. Hamad, S. Askar // Sustainable Engineering and Innovation. – 2021. – Vol. 3, №2. – P. 148–159.

Додаток А. Датасет погоди м. Києва для навчання нейромережі

Input1	Input2	Input3	Input4	Output1	Output2	Output3	Output4	Output5	Output6
0.5	0.35	0.8	0.1	0.4	0.1	0.01	0.2	0.1	0.6
0.6	0.35	0.9	0.9	0.5	0.3	0.01	0.3	0.1	0.6
0.5	0.4	0.7	0.5	0.4	0.01	0.01	0.4	0.1	0.2
0.4	0.2	0.6	0.1	0.5	0.0	0.01	0.3	0.4	0.5
0.3	0.25	0.5	0.1	0.6	0.0	0.3	0.5	0.5	0.8
0.1	0.3	0.6	0.5	0.4	0.0	0.6	0.4	0.1	0.2
0.01	0.15	0.5	0.5	0.6	0.0	0.5	0.6	0.1	0.6
0.1	0.2	0.5	0.5	0.6	0.0	0.5	0.5	0.1	0.7
0.3	0.2	0.6	0.5	0.6	0.0	0.1	0.6	0.9	0.2
0.4	0.2	0.7	0.9	0.4	0.0	0.01	0.6	0.6	0.01
0.4	0.35	0.7	0.1	0.4	0.1	0.01	0.3	0.1	0.3
0.5	0.35	0.8	0.5	0.5	0.1	0.01	0.4	0.1	0.7

Додаток Б. Датасет погоди м. Оклахома для навчання нейромережі

Input1	Input2	Input3	Input4	Output1	Output2	Output3	Output4	Output5	Output6
0.4	0.55	0.7	0.9	0.7	0.7	0.8	0.9	0.6	0.7
0.5	0.75	0.7	0.9	0.8	0.6	0.7	0.8	0.7	0.7
0.2	0.9	0.58	0.9	0.6	0.7	0.6	0.7	0.4	0.6
0.1	0.85	0.59	0.9	0.7	0.4	0.7	0.8	0.3	0.6
0.1	0.55	0.76	0.9	0.6	0.2	0.5	0.6	0.2	0.6
0.01	0.3	0.73	0.9	0.5	0.1	0.4	0.4	0.1	0.8
0.01	0.2	0.7	0.9	0.4	0.1	0.3	0.5	0.01	0.7
0.01	0.35	0.67	0.9	0.6	0.1	0.3	0.4	0.01	0.7
0.01	0.4	0.54	0.9	0.8	0.1	0.6	0.6	0.01	0.5
0.01	0.55	0.63	0.9	0.9	0.1	0.7	0.6	0.01	0.6
0.2	0.55	0.59	0.9	0.7	0.5	0.6	0.7	0.1	0.5
0.2	0.5	0.54	0.9	0.7	0.7	0.8	0.6	0.1	0.5

Додаток В. Перелік зауважень нормоконтролера

[illegible]