

Міністерство освіти і науки України
Харківський національний університет радіоелектроніки

Факультет _____ Комп'ютерних наук
(повна назва)

Кафедра _____ Програмної інженерії
(повна назва)

КВАЛІФІКАЦІЙНА РОБОТА
Пояснювальна записка

рівень вищої освіти _____ другий (магістерський)

Дослідження методів машинного навчання

для прогнозування погодних умов

(тема)

Виконав:

Випускник 2 курсу, групи ІПЗм-19-2

Маначенко М.В.

(прізвище, ініціали)

Спеціальність

121- Інженерія програмного
забезпечення

(код і повна назва спеціальності)

Тип програми

Освітньо-наукова

(освітньо-професійна або освітньо-наукова)

Керівник

доц. Каук В.І.

(посада, прізвище)

Допускається до захисту
Зав. кафедри

(підпис)

З.В. Дудар

(прізвище, ініціали)

2021р.

Харківський національний університет радіоелектроніки

Факультет Комп'ютерних наук
(повна назва)

Кафедра Програмної інженерії
(повна назва)

Рівень вищої освіти другий (магістерський)

Спеціальність 121- Інженерія програмного забезпечення
(код і повна назва спеціальності)

Тип програми Освітньо-наукова
(освітньо-професійна або освітньо-наукова)

Освітня програма Інженерія програмного забезпечення
(повна назва)

ЗАТВЕРДЖУЮ:

Зав. кафедри _____

(підпис)

« 26 » березня 2021 р.

ЗАВДАННЯ НА КВАЛІФІКАЦІЙНУ РОБОТУ

студента Маначенко Маргарити Вікторівни
(прізвище, ім'я, по батькові)

- Тема роботи Дослідження методів машинного навчання для прогнозування погодних умов
затверджена наказом університету від 26.03.2021 № 385
- Термін подання роботи до екзаменаційної комісії 18 травня 2021р.
- Вихідні дані до роботи електронні ресурси теми, порівняльні аналізи архітектур нейронних мереж, методи передбачень рядів, ресурс датасетів Kaggle, середовище розробки PyCharm, мова Python, бібліотеки Keras, ReactJs
- Перелік питань, що потрібно опрацювати в роботі аналіз предметної області і постановка задачі, визначення можливостей різних архітектур нейронних мереж для прогнозу часових рядів, пошук датасету, створення та навчання моделей нейронних мереж для прогнозування, проведення експерименту, формування рекомендацій.
- Перелік графічного матеріалу із зазначенням креслеників, схем, слайдів, ілюстрацій актуальність дослідження, мета, постановка задачі, аналіз проблемної області, архітектури нейронних мереж, вибір інструментів, планування експерименту, програмна реалізація, результати, висновки.

6. Консультанти розділів роботи

Найменування розділу	Консультант (посада, прізвище, ім'я, по батькові)	Позначка консультанта про виконання розділу	
		підпис	дата
Спецчастина	доц. Каук В.І		11.05.21

КАЛЕНДАРНИЙ ПЛАН

№	Назва етапів роботи	Терміни виконання етапів роботи	Примітка
1	Аналіз предметної області	25.01.21 – 11.02.21	виконано
2	Огляд існуючих методів	10.02.21 – 12.02.21	виконано
3	Постановки задачі	13.02.21 – 17.02.21	виконано
4	Дослідження існуючих архітектур нейронних мереж для часових рядів	18.02.21 – 24.02.21	виконано
5	Пошук датасетів для експерименту	16.02.21 – 21.02.21	виконано
6	Планування експерименту, огляд інструментів	24.02.21 – 07.03.21	виконано
7	Створення та тренування моделей	07.03.21 – 28.03.21	виконано
8	Програмна реалізація веб-додатку	28.03.21 – 10.04.21	виконано
9	Проведення експерименту	05.04.21 – 14.04.21	виконано
10	Оформлення статті	16.04.21 – 26.04.21	виконано
11	Підготовка пояснювальної записки	01.04.21 – 4.05.21	виконано
12	Підготовка презентації та доповіді	6.05.21 – 12.05.21	виконано
13	Нормоконтроль	12.05.21 – 18.05.21	виконано
14	Рецензування	16.05.21 – 19.05.21	виконано
15	Занесення диплома в електронний архів	18.05.21	виконано
16	Попередній захист	19.05.21	виконано
17	Допуск до захисту у зав. кафедри	21.05.21	виконано

Дата видачі завдання 25 січня 2021р.Студент _____
(підпис)Керівник роботи _____ доц. Каук В. І.
(підпис) (посада, прізвище, ініціали)

РЕФЕРАТ / ABSTRACT

Пояснювальна записка до кваліфікаційної роботи: 72с., 11рис., 18 дж.

БАГАТОШАРОВИЙ ПЕРЦЕПТРОН РУМЕЛЬХАРТА, ЗГОРТКОВА НЕЙРОННА МЕРЕЖА, МАШИННЕ НАВЧАННЯ, НЕЙРОННА МЕРЕЖА, ПРОГНОЗУВАННЯ ПОГОДИ, РЕКУРЕНТНА НЕЙРОННА МЕРЕЖА, PYTHON.

Об'єктом дослідження є температурні показники повітря у різноманітних територіальних місцевостях світу. Предмет дослідження – існуючі методи прогнозування погодних умов, що базуються на використанні технологій нейронних мереж.

Методи розробки базуються на мові програмування Python і технологіях Keras та TensorFlow. У роботі проаналізовані такі архітектурні підходи та класи нейромереж: повнозв'язна нейронна мережа прямого поширення, згорткова та рекурентна нейронні мережі.

У результаті роботи побудовано та натреновано моделі, які можуть використовуватися для подальшого прогнозування погодних умов, та сконструйовано веб-додаток для отримання прогнозу на заданій території.

Explanatory note to the qualification work: 72 p., 11 fig., 18 sources.

CONVOLVED NEURAL NETWORK, MACHINE LEARNING, NEURAL NETWORK, MULTILAYER PERCEPTRON, PYTHON, RECURRENT NEURAL NETWORK, WEATHER FORECASTING.

The object of the study is the air temperature in different areas of the Earth. The subject of the research is the existing methods of weather forecasting based on the neural network technologies.

Development methods are based on the Python programming language and Keras and TensorFlow technologies. Convolved neural networks, fully connected feed-forward neural networks and recurrent neural network were analyzed in this paper.

As a result of the work, models were built and trained that can be used for further forecasting of weather conditions, and a web application was constructed to obtain a forecast in a given area.

Я, Маначенко Маргарита Вікторівна, студентка гр. ПЗм-19-2, здобувач вищої освіти на другому (магістерському) рівні кафедри «Програмна інженерія», заявляю: моя кваліфікаційна робота на тему «Дослідження методів машинного навчання для прогнозування погодних умов», що буде представлена в екзаменаційну комісію для публічного захисту, виконана самостійно, в ній не містяться елементи плагіату і вона може бути опублікована в електронному архіві відкритого доступу EIAr KhNURE. Всі запозичення з друкованих та електронних джерел мають відповідні посилання.

Я ознайомена з діючим положенням «Про протидію академічному плагіату в ХНУРЕ», згідно з яким виявлення плагіату є підставою для відмови в допуску кваліфікаційної роботи до захисту та застосування дисциплінарних заходів.

ЗМІСТ

Вступ.....	8
1 Аналіз предметної області.....	10
1.1 Аналіз процесу прогнозування погодніх умов	10
1.2 Методи прогнозування погодніх умов	13
1.3 Метрики точності прогнозування	18
1.4 Значення прогнозу погодніх умов.....	20
1.5 Постановка задачі.....	25
2 Аналіз методів для дослідження.....	27
2.1 Огляд існуючих датасетів	27
2.2 Огляд API для прогнозування	28
2.3 Аналіз обраних методів для дослідження	29
3 Проведення дослідження.....	35
3.1 Підготовка до експерименту.....	35
3.2 Використання MLP архітектури.....	38
3.3 Використання LSTM архітектури	41
3.4 Використання CNN архітектури	43
3.5 Оцінка результатів у веб-додатку	46
Висновки	49
Перелік джерел посилань.....	51
Додаток А Перелік джерел посилання за науковими напрямками керівника та науковців кафедри програмної інженерії	53
Додаток Б Звіт результатів перевірки кваліфікаційної роботи на унікальність тексту.....	54
Додаток В Наукові публікації	55
Додаток Г Слайди презентації	59

Додаток Д Лістинг модуля програми	67
Додаток Е Експертний висновок результатів перевірки кваліфікаційної роботи на відповідність оформлення вимогам ДСТУ 3008:2015	73

ВСТУП

З розвитком цивілізації важливість прогнозу погоди для людства тільки продовжує збільшуватися. Практично кожна людина приймає рішення, що залежать від погодних умов, щодня, іноді незначні, іноді величезної важливості. Незважаючи на значні зусилля метеорологів в області прогнозування, інформація про стан погоди все ще буває недостатньою і недостовірною.

Задача підвищення ефективності методів прогнозу метеорологічної обстановки на даний момент залишається актуальною для науки. Це пояснюється складністю проблеми, яка потребує залучення методів, розвинених у рамках різноманітних напрямках наукового пізнання, а також постійним вдосконаленням інструментарію, який може бути використаний у цих цілях.

На даний момент у світі існує досить розвинена система глобального прогнозу. Вона включає в себе єдину мережу станцій спостереження за метеорологічними величинами. Прогнозування погоди спирається на великомасштабну інтерпретацію синхронних даних наявних станцій спостереження і проводиться на основі методів синоптичної і динамічної метеорології[1]. Цим і визначається завчасність і реальна точність виконуваного прогнозу.

Більш високі вимоги пред'являються до точності короткострокових (на строк в межах однієї доби) прогнозів, що вимагає наявності в даному районі локальної станції спостережень метеорологічних величин. Останнім часом, у зв'язку з появою автономних портативних метеостанцій, проблема локального прогнозу знову стає об'єктом інтересу та уваги дослідників[2].

Інтерес до локального короткострокового та довгострокового прогнозувань погодних явищ має практичну основу. Це, в першу чергу, існування небезпечних метеорологічних явищ, які здатні завдати шкоди життю людини, промисловості, сільськогосподарським об'єктам і транспорту. До їх числа відносяться явища погоди,

пов'язані з вітром (шквали, смерчі, хуртовини), ожеледь, ожеледиця, обмеження видимості через тумани і опадів тощо.

На сьогоднішній день масово використовуються традиційні методи одновимірної метеорології: регресійний аналіз, фільтрація даних, розрахунок середніх багаторічних величин і т.д.[2]. Дані методи можуть бути істотно доповнені за рахунок вдосконалення використовуваних алгоритмів і обчислювальних засобів. Одним із перспективних напрямків досліджень є вивчення та аналіз алгоритмів штучних нейронних мереж.

Метою роботи є дослідження актуальних методів аналізу прогнозування погодних умов. У ході дослідження буде проаналізовані методи, що використовують машинне навчання, а саме: нейронні мережі.

Об'єкт дослідження – температурні показники повітря у різноманітних територіальних місцевостях по всьому світу.

Предмет дослідження – існуючі методи прогнозування погодних умов з використанням нейронних мереж.

Результати даного дослідження будуть корисні з теоретичної точки зору для розуміння шляхів вирішення актуальних проблем метеорології. З практичної точки зору є можливим використання моделей, що були натреновані у ході роботи, для прогнозування погодних умов.

1 АНАЛІЗ ПРЕДМЕТНОЇ ОБЛАСТІ

1.1 Аналіз процесу прогнозування погодних умов

Прогноз погоди – науково обґрунтоване припущення про майбутні зміни погодних умов, сформовані на основі аналізу розвитку великомасштабних атмосферних процесів.

Прогнози погоди поділяються на короткострокові (від декількох годин до 1-2 діб), довгострокові малої завчасності (3-10 діб), довгострокові великої завчасності (на місяць і більше).

Процес прогнозу метеорологічних явищ має справу з ймовірними процесами, яким неминуче властива та чи інша ступінь невизначеності. За останні десятиріччя світове метеорологічне співтовариство досягло значних успіхів у розвитку технологій чисельного прогнозу погоди. Сьогодні, наприклад, прогнози на три доби для приземного тиску настільки ж успішні, як прогнози на добу 20 років тому.

Щоб прогнозувати погоду треба знати, що відбувається в атмосфері на даний момент, в початковий момент часу. Дані гідрометеорологічних спостережень – вхідні данні для розрахунку метеорологічного прогнозу. Щоб підготувати прогноз на декілька днів вперед, треба мати дані про фактичну погоду на території з масштабами декількох тисяч кілометрів. Прогноз на тиждень і далі потребує інформацію про те, що відбувається з погодою по всій земній кулі. При довгостроковому прогнозі доводиться розглядати практично всю кліматичну систему, в яку входять атмосфера, океан і верхній шар суші.

Поточний стан атмосфери завжди відомо лише приблизно, так як спостереження за атмосферою є неповними і неточними – спостережна мережа подекуди недостатньо щільна і дані спостережень іноді містять помилки. Великі області планети (океани, високі і тропічні широти) залишаються слабо освітленими даними спостережень. На території нашої країни щільність і оснащеність

спостережної мережі також залишають бажати кращого. Можна підвищувати щільність мережі і зменшувати похибки вимірювань, але не нескінченно – можливості такої деталізації обмежені, тому наше знання поточного стану атмосфери ніколи не буде повним.

Основним прогностичним інструментом сьогодні залишаються чисельні моделі атмосфери – вони відтворюють властивості атмосфери і стають все більш досконалішими. Що з себе являє сучасна прогностична модель атмосфери? Це складний програмний комплекс (трудовитрати на розробку становлять сотні людино-років), який вирішує систему рівнянь, що описує еволюцію атмосфери, тобто розраховує температуру, вологість, вітер і інші параметри на різних висотах в різних точках земної кулі. У моделі враховуються процеси термогідродинаміки, перетворень вологи, радіаційно-хмарні взаємодії та інші.

Деякі фізичні процеси в моделях не враховуються свідомо через те, що вони менше впливають на успішність прогнозу. Інші огрубляються, тому що їх розрахунок вимагає великих обчислювальних ресурсів. Розрахунок прогнозів погоди – одна з найбільш «жадібних» до комп'ютерних ресурсів завдань, що вирішуються сьогодні вченими. Серед факторів, що впливають можна виділити більш і менш важливі, але, в кінцевому рахунку, велика кількість «дрібниць» впливає на якість прогнозів.

На сьогоднішній день автоматизовані прогностичні технології не здатні прогнозувати деякі погодні явища. Це пов'язано з тим, що багато явищ погоди, включаючи небезпечні явища, мають локальний характер і складну природу, яку в даний час важко описати формально для повної автоматизації прогнозу з прийнятним рівнем успішності. З цієї причини цілий ряд явищ погоди (наприклад, тумани, ожеледь) прогноуються в основному фахівцями-синоптиками на місцях, які добре знають умови їх утворення і розвитку в конкретному регіоні. Результати модельних розрахунків синоптики використовують як основу для складання остаточних, «офіційних» прогнозів погоди, які передбачають синтез досвіду фахівців-прогнозистів і результатів різних прогностичних технологій.

Проблема передбачуваності прогнозу погоди стала усвідомлюватися вже після перших чисельних експериментів з моделювання еволюції атмосфери на довгі терміни. Ще в 50-х роках було показано, що як завгодно малі помилки завдання початкових даних для розрахунку прогнозу з плином часу трансформуються у великі. За межами приблизно двох тижнів помилки деталізованого по днях модельного прогнозу виростають до рівня помилок випадкового прогнозу. Так виявляються об'єктивні (тобто непереборні при будь-якої кваліфікації прогнозистів) обмеження на можливість точно прогнозувати конкретний хід еволюції атмосферних процесів на досить тривалих інтервалах часу. Обмеження пов'язано з тим, що початкові умови для розрахунку прогнозу завжди містять похибки і початкові помилки мають тенденцію зростати протягом періоду прогнозу через нестійкість атмосферних процесів – «ефект метелика».

Практична передбачуваність атмосфери залежить від цілого ряду чинників, в тому числі і від структури атмосферних течій (тобто від поточної погодної ситуації). В деяких випадках розвиток погодних процесів добре «проглядається» на кілька діб вперед, а буває, що і прогноз на завтра виявляється вельми крихким.

Все це не означає, що ми нічого не можемо точно сказати про майбутнє атмосфери за межами пари тижнів. Можна припустити, але прогнози на довгі терміни формулюються в іншій формі і вимоги до них інші. Як правило для довгострокових прогнозів використовуються імовірнісна формулювання і представлення результатів у термінах середніх за період (наприклад, місяць або сезон) величин. Тобто, немає потреби для сильної деталізації, наприклад, прогноз на кілька тижнів вперед по добі або навіть по хвиликах.

1.2 Методи прогнозування погодних умов

На даний момент прогноз погоди для локального рівня (місто, селище) створюється національними метеорологічними центрами. Для отримання прогнозу погоди на локальному рівні використовуються дані, розраховані на глобальній моделі прогнозу погоди. Так як ці моделі є великомасштабними, то точно вони можуть передбачати тільки погодні системи, що в кілька разів перевищують крок сітки, і тому явища в менших масштабах повинні представлятися в наближеному вигляді з використанням статистичних та інших методів[3]. Ці обмеження в глобальних моделях прогнозу надають особливий вплив на докладні прогнози місцевих елементів погоди, таких, як хмарність і туман, а також екстремальних явищ, таких, як інтенсивні опади та максимальні пориви вітру. Тому необхідне створення прогностичних моделей, адаптованих для локального рівня, що дозволять розраховувати більш точний прогноз погоди. Сукупність локальних моделей прогнозу дозволить підвищити також і точність прогнозу на національному рівні.

1.2.1 Синоптичний метод

Синоптичне прогнозування – це перший традиційний підхід до прогнозування погоди. До кінця 1950-х років цей метод використовувався як основний. Він ґрунтується на побудові і аналізі синоптичних карт, що зображують атмосферні умови в конкретний момент часу. На них виділяються окремі об'єкти (циклони, антициклони, атмосферні фронти), для кожного з яких властиві певні типи погодних умов. Сучасний метеорологічний центр щодня готує серію синоптичних карт. Такі карти складають основу прогнозів погоди. Завдання підготовки синоптичних карт на

постійній основі включає в себе збір та аналіз величезної кількості даних спостережень, отриманих з безлічі метеорологічних станцій.

На основі ретельного вивчення метеорологічних карт протягом багатьох років були сформульовані певні емпіричні правила. Ці правила допомагають метеорологам оцінити швидкість і напрямок руху погодних систем. Наприклад, коли відомий тип погоди, створюваної уздовж фронту, а також швидкість і напрямок руху бурі, можна зробити досить точний прогноз погоди для обраної місцевості.

Проте через раптові перепади в циклонічній системі ці прогнози дійсні протягом лише короткого періоду часу: декілька годин або днів. Прогнозування на більш тривалий період за цим методом не працює.

1.2.2 Модель численного прогнозування погодних умов

Для прогнозу погоди на глобальному рівні в даний час використовуються моделі чисельного прогнозування. Даний метод заснований на побудові математичних моделей атмосфери і моделей взаємодії атмосфери і океану. У ньому вирішуються рівняння гідро- і термодинаміки і використовуються основні фізичні закони. Гази атмосфери підкоряються ряду фізичних принципів, і якщо відомі поточні умови атмосфери, то відомі фізичні закони можуть використовуватися для прогнозування майбутньої погоди.

Основу чисельних методів прогнозу погоди складають гідродинамічні моделі атмосфери. Побудова таких моделей включає ряд етапів:

- визначення та опис фізичних процесів, що призводять до змін погоди;
- вибір диференціальних (чи інших) рівнянь, що описують ці процеси, і при необхідності перетворення рівнянь, записаних в будь-якій системі координат, до системи координат, пов'язаної з картографічними проекціями земної кулі;

- заміна складної, безперервної середовища атмосфери більш простим середовищем з невеликим числом параметрів і значеннями метеорологічних величин в кінцевому числі точок простору;
- чисельне рішення рівнянь і розрахунок значень метеорологічних величин для фіксованих точок простору і моментів часу[4].

Таким чином, метод полягає у процесі узагальнювання і екстраполяції за часом інформації, витягнута з минулих спостережень. Засвоєння даних є досить ефективним в умовах недостатності інформації з різних джерел, що використовуються з метою створення логічно узгодженої оцінки стану атмосфери. Однак, подібно до прогнозу, засвоєння даних базується на моделі численного прогнозу погоди і не може безпосередньо використовувати спостереження таких масштабів і процесів, які не представлені в моделі. Прогнози з завчасністю, що перевищує кілька годин, майже завжди повністю ґрунтуються на даному методі.

Точно можна прогнозувати тільки погодні системи, які в кілька разів перевищують крок сітки, і тому явища в менших масштабах повинні представлятися в наближеному вигляді з використанням статистичних та інших методів. Ці обмеження дають особливий вплив на докладні прогнози місцевих елементів погоди, таких, як хмарність і туман, а також екстремальних явищ, таких, як інтенсивні опади та максимальні пориви вітру. Вони також вносять вклад в невизначеності, які можуть в кінцевому підсумку обмежувати передбачуваність і достовірність моделей.

На даний час для прогнозування погоди використовують такі основні моделі: ADAS, ETA, Aviation, Ensemble, MM5, MRF / GFS, NGM, Meso-ETA. Модель NGM (Nested Grid Model) є однією з найбільш використовуваних моделей для короткострокового прогнозування (менш ніж на 48 годин). Чисельні значення для кожного параметра, що розраховується в моделі, розраховуються кожні 3 або 6 годин, що дозволяє отримувати більш детальну інформацію для різного часу доби. Результати прогнозу публікуються двічі на день. Модель ETA є іншою точною моделлю прогнозу погоди на період до 48-84 годин. Ця модель дозволяє отримати

прогноз такої же деталізації як і модель NGM. Результати прогнозу публікуються чотири рази на день. Модель GFS (Global Forecast System) також є не менш точною, ніж модель NGM. Вона особливо корисна для прогнозу на проміжку 48-72 години, на якому модель NGM вже не розраховує прогноз. Розширена версія GFS (GFSX) дозволяє отримувати прогноз погоди аж до двох тижнів в майбутнє, але точність прогнозу різко падає при прогнозі більш ніж на тиждень[4].

Зазначені моделі є великомасштабними, тому з їх допомогою можливе прогнозування лише величин, усереднених за площею елементарного осередку прогностичної моделі. За допомогою таких усереднених значень можна охарактеризувати основний стан погоди, або її «фон». Але в атмосфері також відбуваються процеси менших, ніж елементарний осередок, масштабів, які не враховуються в глобальній моделі. Тому для прогнозування цих процесів і відповідної їм погоди на рівні міста чи району розробляються спеціальні локальні прогностичні моделі.

Використання таких моделей для локального рівня є складним, так як для їх реалізації необхідні значні витрати, як фінансові (великі обчислювальні потужності), так і інтелектуальні (розробка математичної моделі прогнозу, адаптованої для локального рівня).

1.2.3 Статистичні методи

Коли розглядається мінлива атмосфера, необхідно враховувати велику кількість змінних. Це дуже складна задача. Для її вирішення були підготовлені чисельні моделі, які ігнорують деякі змінні в припущенні, що деякі аспекти атмосфери не змінюються з часом. Це дозволяє знизити вимоги до продуктивності комп'ютерів, але одночасно знижується і якість прогнозу.

Статистичні методи часто доповнюють чисельний метод. Вони використовують минулі записи метеорологічних даних, роблячи припущення, що в майбутньому погодні умови будуть повторюватися.

Основна мета вивчення минулих метеорологічних даних – виявити ті метеорологічні аспекти, які є показниками майбутніх подій. Але таким чином можна робити прогноз погоди з великим кроком по території. Це особливо корисно при проектуванні тільки одного аспекту погоди за раз. Наприклад, це має велике значення для довгострокового прогнозування максимальної температури протягом дня в певному місці. Процедура полягає в зборі статистичних даних, що стосуються температури, швидкості і напрямку вітру, кількості хмарності, вологості конкретного сезону року[5]. Статистичний метод має велике значення для довгострокових прогнозів погоди.

1.2.4 Нейронні мережі

Іншим варіантом вирішення задачі прогнозування погоди є використання нейронних моделей.

Нейронні мережі натхнені біологічними нейронами головного мозку, які працюють у складній мережі взаємодій для передачі, збору та вивчення інформації на основі історії вже зібраної інформації. Нас цікавлять обчислювальні нейронні мережі, подібні до нейронів мозку тим, що вони є сукупністю нейронів (вузлів), які приймають вхідні сигнали (числові величини), обробляють вхідні дані і передають оброблені сигнали іншим низхідним агентам в мережі. Обробка сигналів як числових величин, що проходять через нейронну мережу, є дуже потужною функцією, яка не обмежується лінійними залежностями.

Нейронні мережі добре зарекомендували себе в областях, де необхідне застосування людського інтелекту, зокрема, при вирішенні задач класифікації, розпізнавання образів і аналізу часових рядів. За допомогою нейронних мереж можливо моделювання нелінійної залежності майбутнього значення часового ряду від його минулих значень і від значень зовнішніх факторів. Отже, при вирішенні завдань прогнозування роль нейронної мережі полягає в передбаченні майбутньої реакції системи по її попередній поведінці[6].

Можливість використання нейронних мереж для прогнозу погоди досліджується протягом тривалого часу. Перевага нейронних мереж полягає в тому, що вони добре описують поведінку нелінійних систем, до яких входить модель погодного прогнозу.

Основний вигаш від використання нейронних мереж полягає в тому, що їм не потрібно вирішувати складні фізичні рівняння і зберігати величезні обсяги інформації. Спочатку, необхідно зібрати деякий архів даних, на основі яких буде виконано прогноз. Дані розбиваються на частини: навчальну і тестуючу вибірки, які потім подаються на вхід мережі. Потім програма самостійно аналізує данні і виділяє закономірності. Результатом прогнозування часового ряду є значення такого ж ряду в необхідний момент часу. Існує логічна залежність: чим більше тренувальний набір, тим точніше буде прогноз.

1.3 Метрики точності прогнозування

Для будь-якої моделі машинного навчання питання стабільності є актуальним. Якщо модель пристосована до навчальних даних, немає гарантії, що вона буде точно працювати для реальних. Потрібно мати впевненість в тому, що модель отримала

більшість шаблонів саме із «правильних» даних, отже у неї низький рівень зміщення і дисперсії.

На даний момент основний засіб для цього полягає у видаленні частини навчальних даних і використанні їх для отримання прогнозів з моделі, навченої для інших даних. Далі оцінка помилки показує, як модель працює з невидимими даними або набором перевірок. Це простий метод перехресної перевірки, також відомий як метод утримання. Даний метод має проблему високої дисперсії, це пов'язано з тим, що невідомо, які точки даних виявляться в наборі перевірки, і результат може бути абсолютно різним для різних наборів.

Оскільки даних для навчання моделі ніколи не буває достатньо, видалення їх частини для перевірки створює проблему недостатнього відповідності. Скорочуючи дані навчання, ми ризикуємо втратити важливі тренди в наборі даних, що, в свою чергу, збільшує помилку, викликану зміщенням. K Fold Cross валідація – метод, який надає достатньо даних для навчання моделі, а також залишає достатньо даних для перевірки.

У процесі K Fold Cross валідації дані діляться на k підмножин. Тепер метод утримання повторюється k разів, так що кожен раз одне з k підмножин використовується в якості тестового набору / набору перевірки, а інші $k-1$ підмножини об'єднуються для формування навчального набору. Оцінка помилок усереднюється за всіма k випробуваннями, щоб отримати загальну ефективність даної моделі. Отже, кожна точка даних потрапляє в набір перевірки рівно один раз і потрапляє в навчальний набір $k-1$ разів. Це значно зменшує зсув, оскільки ми використовуємо велику частину даних для підгонки, а також значно зменшує дисперсію, оскільки велика частина даних також використовується в наборі перевірки. Заміна навчальних і тестових наборів також підвищує ефективність цього метода.

Наступний метод перехресної перевірки Leave-P-Out залишає p точок даних за межами навчальних даних. Тобто якщо у вихідній вибірці є n точок даних, то $n-p$ вибірки використовуються для навчання моделі, а p точок використовуються в якості

набору перевірки. Це повторюється для всіх комбінацій, в яких вихідний зразок може бути розділений таким чином, а потім помилка усереднюється для всіх випробувань, щоб дати загальну ефективність[7].

1.4 Значення прогнозу погодних умов

У розвинених країнах світу погода і клімат давно стали економічними категоріями. Щороку стихійні лиха забирають близько 250 000 людських життів, розмір збитку, що наноситься майну, становить в межах 50-100 млрд. доларів США.

Світова статистика показує: якщо довіряти гідрометеорологічної інформації і адекватно на неї реагувати, то можна запобігти від 30 до 40% втрат і повністю уникнути людських жертв[8]. Особливо помітний економічний ефект дає використання метеорологічної інформації в авіації, енергетиці, будівництві, рибальстві і судноплавстві, сільському господарстві.

1.4.1 Погода і громадське життя

Більшу кількість кінцевих користувачів прогнозів погодних умов становлять представники широкої громадськості. Від погоди залежить не тільки одяг, який слід одягати у конкретний момент часу, а і самопочуття багатьох людей. Наприклад, зміна атмосферного тиску безпосередньо впливає на стан судин і серця. Тому знання майбутніх змін в погоді дозволить категорії людей своєчасно вжито заходів профілактичного характеру та зменшити їх наслідки змін погодних умов для організму.

Грози можуть створювати сильний вітер та небезпечні удари блискавки, що може призвести навіть до загибелі людей, відключення електроенергії та завдати шкоди градом. Сильний сніг або дощ можуть перевести транспорт і торгівлю в нерухомий стан, а також спричинити повені у регіонах, розташованих у низинах. Надмірна спека або холодні хвилі можуть бути смертельними або завдати значної шкоди тим, хто не має належних комунальних послуг, а посуха може вплинути на використання води та знищити рослинність.

У деяких країнах сформовані державні установи для надання прогнозів, попереджень та консультацій громадськості з метою захисту життя і власності та підтримки комерційних інтересів. Знання того, що потрібно кінцевому користувачеві з прогнозу погоди, повинно враховуватися, щоб подавати інформацію корисно та зрозуміло. Прикладами можуть бути Національна служба погоди (NWS) Національної адміністрації океанів і атмосфери, Метеорологічна служба Канади (MSC).

1.4.2 Погода і економічна безпека території

Залежність стійкого розвитку народного господарства будь-якої держави або регіону від гармонійного співіснування суспільства і навколишнього природного середовища вже не потребує доказів. Природа впливає на господарську діяльність людини двояко: з одного боку, стихійні екологічні і гідрометеорологічні лиха завдають значної шкоди економіці, але з іншого – достовірна інформація про погоду і клімат формує додатковий ресурс економічної ефективності. Це означає, що підприємства можуть мінімізувати втрати і збитки від несприятливих погодних умов і максимізувати вигоду за рахунок раціонального використання сприятливих факторів природного середовища. Чим ретельніше використовується інформація про погоду і клімат у всіх сферах економіки, тим стійкіше економіка до всіх проявів стихії.

Господарюючі суб'єкти повинні мати чітке уявлення про ступінь впливу на виробничу діяльність тих чи інших погодних умов, їм необхідно розробити «метеоролого-економічну модель» попереджувальних дій[8]. Завдання метеорологів – безперервне відстеження всіх змін, що відбуваються в природі, прогнозування загрози виникнення несприятливих умов погоди, їх розвитку та своєчасне попередження про них виробничників. Чим вище рівень взаємодії, тим менше ймовірність бути захопленим стихією знезапче.

1.4.3 Погода і авіація

Оскільки авіаційна промисловість особливо чутлива до погоди, точне прогнозування погоди має важливе значення. Туман або сильна хмарність можуть перешкоджати посадці та зльоту багатьох літаків. Турбулентність та обледеніння також є значною небезпекою в польоті. Грози є проблемою для всіх літаків через сильну турбулентність, висхідні потоки та межі вильоту, обледеніння – через сильні опади. Град, сильний вітер та блискавки – це все може завдати серйозної шкоди літаку у польоті. Вулканічний попел також є значною проблемою для авіації.

Для авіалайнерів важливо зуміти скористатися перевагами потоку реактивного потоку для поліпшення паливної ефективності. Перед вильотом екіпаж отримує інструктаж про умови, яких очікуються на шляху, і в пункті призначення. Крім того, аеропорти часто змінюють рішення, яка злітно-посадкова смуга використовується для отримання переваг вітру. Це зменшує відстань, необхідну для зльоту, та усуває потенційний побічний вітер.

Крім того, погодна інформація дозволяють планувати будь-які туристичні поїздки. Кожна людина, скориставшись джерелами телерадіомовлення або інтернет-

ресурсом, може дізнатися, чи буде здійснений цікавить його рейс, яка погода чекає на в тому чи іншому місці земної кулі.

1.4.4 Погода та судноплавство

Комерційне та рекреаційне використання водних шляхів може суттєво обмежуватися напрямком та швидкістю вітру, періодичністю та висотою хвиль, припливами та опадами. Кожен із цих факторів може впливати на безпеку морського транзиту. Отже, було створено різноманітні коди для ефективної передачі детальних прогнозів морської погоди пілотам суден за допомогою радіо, наприклад MAROF (морський прогноз).

Залежність флоту від погоди проявляється завжди: коли суди знаходяться на маршрутах і в районах лову і коли відстоюються в порту. Штормовий вітер, сильне хвилювання, обмерзання, туман і інші явища здатні привести судно до загибелі.

1.4.5 Погода і сільське та лісове господарства

На динаміку врожайності сільськогосподарських культур можуть вплинути різні чинники, наприклад, посуха, туман, заморозки та інші. Використання прогнозів погоди дозволяє фермерам та сільськогосподарським організаціям чіткіше планувати свою діяльність. Наприклад, тривалі періоди сухості можуть зіпсувати посіви бавовни, пшениці та кукурудзи. Хоча посіви кукурудзи можуть бути зруйновані посухою, їх висушені залишки можуть бути використані як замітник корму для худоби у вигляді силосу. Морози та заморозки руйнують урожай як навесні, так і

восени. Наприклад, у персикових дерев у повному розквіті може бути знищений їхній потенційний урожай персика весняними заморозками.

Прогноз погоди вітру, опадів та вологості має важливе значення для запобігання та боротьби з пожежами. Розроблені різні індекси, такі як індекс погоди лісових пожеж та індекс Хейнса, щоб передбачити райони, яким більше загрожує виникнення пожежі з природних чи людських причин. Умови розвитку шкідливих комах можна передбачити, також прогнозуючи розвиток погоди.

1.4.6 Погода та енергетичний сектор

Електроенергетичні та газові компанії покладаються на прогнози погоди, щоб передбачити попит, на який погода може сильно вплинути. Вони використовують величину, яка називається градусним днем, щоб визначити, наскільки потужним буде використання для опалення (градусний день опалення) або охолодження (охолоджувальний день градусу). Ці кількості базуються на середньодобовій температурі 18°C. Холодніші температури змушують до нагрівання градусні дні (один на градус Фаренгейта), тоді як більш теплі температури примушують охолоджувати градусні дні.

Взимку сильна холодна погода може спричинити сплеск попиту, оскільки люди підключають опалення. Подібним чином, влітку сплеск попиту може бути пов'язаний із збільшенням використання систем кондиціонування в спекотну погоду. Передбачаючи сплеск попиту, комунальні компанії можуть придбати додаткові поставки електроенергії або природного газу до того, як зростуть ціни, або, за певних обставин, поставки обмежуються через використання відключень та відключень.

1.4.7 Погода і торгівля

Дуже часто приватні компанії замовляють прогнози погоди з урахуванням їх потреб, щоб вони могли збільшити свій прибуток або уникнути великих збитків. Наприклад, мережі супермаркетів можуть міняти запаси на своїх полицях в очікуванні різних звичок споживчих витрат за різних погодних умов. Прогнози погоди можна використовувати для інвестицій на товарний ринок, таких як ф'ючерси на апельсини, кукурудзу, сою та олію [8].

1.5 Постановка задачі

Метою роботи є дослідження актуальних підходів прогнозування погодних умов. На даний момент застосування нейронних мереж для даної задачі є актуальним і перспективним. Отже, дослідження буде проведено з метою отримання знань про можливість прогнозування метеорологічних даних за допомогою нейронних мереж з різними типами архітектур. Були обрані такі класи нейронних мереж:

- багат шаровий перцептрон Румельхарта (Multilayer Perceptron, MLP);
- рекурентна нейронна мережа (Recurrent Neural Network, RNN);
- згорткова нейронна мережа (Convolutional Neural Network, CNN).

Для дослідження будуть використані загальнодоступні дані, що базуються на даних GISTEMP – це дані глобальної зміни температури, що розповсюджуються Національним інститутом космічних досліджень імені Годдарда (NASA-GISS). Домен зміни температури FAOSTAT розповсюджує дану статистику середньої зміни температури за країнами з щорічними оновленнями. Поточне розповсюдження охоплює період 1745 - 2015 років.

Для дослідження буде використана інформація замірів щомісячної температури протягом останніх 270 років у 180 територіальних утвореннях. Об'єм даних нараховує 577 500 записів. Для кожної країни кількість вимірів складає приблизно 3500. Отже, для кожної країни датасет буде розділено на дві частини: 1750 для тренувального набору та 1750 для тестувального набору.

Буде розроблено веб-додаток, за допомогою якого користувач зможе отримати довгостроковий прогноз температурного стану у будь-якій країні світу. Dodatok bude використовувати три варіанти попередньо тренованих нейронних мереж: рекурентна нейронна мережа, згорткова нейронна мережа і повнозв'язна нейронна мережа прямого поширення.

2 АНАЛІЗ МЕТОДІВ ДЛЯ ДОСЛІДЖЕННЯ

2.1 Огляд існуючих датасетів

Відомо, що ефективність моделей машинного навчання безпосередньо залежить від якості вихідного датасета. Для виконання задачі необхідна очищена вибірка без помилок, викидів і пропущених значень, але з повним набором даних. Однак, в реальності бувають датасети з некоректною або неповною інформацією, отже потрібно багато часу на підготовку до моделювання: очищення, нормалізацію і генерацію змінних.

Існує три загальних способу збору чужих великих даних для власних задач:

- використання готових датасетів;
- робота зі веб-платформами, які надають статистику;
- використання інформації зі сторонніх сайтів.

Тема прогнозування метеорологічних умов за допомогою машинного навчання є дуже популярною у світі, тому датасетів на дану тему дуже велика кількість. У якості джерела вхідних даних було прийнято рішення використовувати платформу Kaggle. Це публічна веб-платформа, на якій користувачі та організації можуть публікувати набори даних, досліджувати і створювати моделі, взаємодіяти з іншими фахівцями та інженерами по машинному навчання, організовувати конкурси з дослідження даних і брати участь в них.

Також, Kaggle проводить змагання серед компаній та користувачів на найкращі моделі для опису і прогнозування даних, тому в системі розміщені найкращі за якістю набори відкритих даних.

Серед доступних датасетів на Kaggle був вибраний датасет глобальної зміни температури, що базуються на даних GISTEMP. Данна інформація дані були отримана завдяки спостереженням Національного інституту космічних досліджень імені Годдарда. Центр Годдарда – це намасштабніша дослідницька лабораторія НАСА.

Центр є найбільшою організацією навчальних та інженерних служб у США, що вивчає Землю, Сонячну систему та Всесвіт за допомогою космічних інструментів

Даний датасет містить статистичні дані щодо щомісячних, сезонних та річних середніх температур, тобто зміни температури щодо базової кліматології, що відповідає періоду останніх 270 років.

Для дослідження буде використана інформація замірів щомісячної температури протягом останніх 270 років у 180 країнах та територіальних утвореннях. Інформація щодо змін температур представлена по столицях країн. Об'єм даних нараховує близько 577 500 записів

3.2 Огляд API для прогнозування

Машинне навчання – це технологія, яка допомагає додаткам на основі штучного інтелекту навчатися і видавати результати автоматично, без людського втручання. Робота складається зі збору, систематизації і аналізу дані, а потім на основі отриманої інформації створення алгоритмів для штучного інтелекту. Мова програмування Python найкраще підходить для виконання таких завдань, тому що вона досить зрозуміла і у неї відмінна продуктивність при обробці даних[9].

Одна з основних причин, чому Python використовується для машинного навчання полягає ще в тому, що у нього є безліч фреймворків, які спрощують процес написання коду і скорочують час на розробку.

У наукових розрахунках використовується бібліотека NumPy. NumPy – це розширення мови Python, що дає підтримку великих багатомірних масивів та матриць, а також обширну бібліотекою високорівневих математичних функцій для операцій з цими масивами.

Pandas – бібліотека на мові Python для обробки та аналізу даних. Робота pandas з даними побудована поверх бібліотеки NumPy. Вона дозволяє оперувати спеціальними структурами даних та операції для маніпулювання числовими таблицями та часовими рядами.

Для вирішення задач побудови, тренування нейронних мереж використовується бібліотека TensorFlow, розроблена компанією Google. TensorFlow забезпечує набір робочих процесів для розробки та навчання моделей, а також інструменти для легкого розгортання в хмарі, у браузері чи на пристрої. TensorFlow використовується для створення широкомасштабних нейронних мереж з багатьма шарами. Бібліотека в основному використовується для проблем глибокого навчання або машинного навчання, таких як класифікація, сприйняття, прогнозування та інших.

Інше актуальне рішення має назву Keras – це відкрита нейромережева бібліотека. Вона представляє собою надбудову над фреймворками DeepLearning4j, TensorFlow та Theano. Направлена на швидку роботу із серіями глибокого навчання, при цьому спроектована бути компактною, модульною та розширюваною[10].

3. 3 Аналіз обраних методів для дослідження

3. 3.1 Багатошаровий перцептрон Румельхарта

Багатошаровий перцептрон або повнозв'язна нейронна мережа прямого поширення – це базова архітектура штучних нейронних мереж, в яких сигнал поширюється строго від вхідного шару до вихідного. Тут повнозв'язність каже про те, що кожен нейрон пов'язаний з усіма нейронами попереднього шару. Дуже прямолінійні, вони передають інформацію від входу до виходу, при цьому в мережі відсутні цикли.

Нейронні мережі часто описуються у вигляді листкового торта, де кожен шар складається з вхідних, прихованих або вихідних клітин. Клітини одного шару не пов'язані між собою, а сусідні шари зазвичай повністю пов'язані (див. рис. 2.1). Найпростіша нейронна мережа має дві вхідних клітини і одну або дві вихідних, і може використовуватися в якості моделі логічних вентилів[11].




Рисунок 2.1 – Модель повнозв'язної нейронної мережі прямого поширення

Багатошаровий перцептрон зазвичай навчається за методом зворотного поширення помилки, в якому мережа отримує безлічі вхідних і вихідних даних. Цей процес називається навчанням з учителем, і він відрізняється від навчання без учителя тим, що в другому випадку безліч вихідних даних мережу становить самостійно. Вищезазначена помилка є різницею між введенням і висновком. Якщо у мережі є достатня кількість прихованих нейронів, вона теоретично здатна змоделювати взаємодію між вхідним і вихідними даними.

Такі мережі широко використовуються і цілком успішно вирішують певний клас завдань: прогнозування, кластеризація і розпізнавання. Також їх часто комбінують з іншими типами нейромереж для отримання нових.

3. 3.2 Рекурентна нейронна мережа

Рекурентні нейронні мережі – це клас нейронних мереж, які добре підходять для задач моделювання послідовних даних, таких як тимчасові ряди або природна мова. Рекурентні нейронні мережі містять зворотні зв'язки, тобто даний клас здатний передавати інформацію від одного кроку мережі до іншого. Завдяки цьому з'являється можливість обробляти серії подій у часі або послідовні просторові ланцюжки.

Існує велика кількість архітектурних рішень для рекурентних мереж. Останнім часом найбільшого поширення набули мережу з довготривалою і короткочасною пам'яттю (LSTM) і керований рекурентний блок (GRU).

LSTM-мережа добре пристосована до навчання на задачах класифікації, обробки і прогнозування часових рядів. Її можна описати як штучну нейронну мережу з LSTM-модулями разом іншими мережевими модулями. LSTM-модуль – це рекурентний модуль мережі, здатний запам'ятовувати значення як на короткі, так і на довгі проміжки часу. Ключем до даної можливості є те, що LSTM-модуль не використовує функцію активації всередині своїх рекурентних компонентів. Таким чином, збережене значення не розмивається в часі, і градієнт не зникає при використанні методу зворотного поширення помилки в часі при навчанні штучної нейронної мережі.

LSTM-модулі часто групуються в блоки, що містять 3-4 вентиля, які використовуються для контролю потоків інформації на входах і на виходах пам'яті даних блоків. Механізм вентилів необхіден для виконання логістичної функції, щоб

отримувати значення в діапазоні $[0;1]$. Далі значення, а точніше, його множення використовується для прийняття рішення щодо допуску або блоку потоку інформації у пам'ять – назовні або всередину. На рисунку 2.2 представлена модель LSTM-блоку з трьома вентилями: вхідним, вихідним і забування. Тут «вхідний вентиль» вирішує, до якої міри нове значення увійде в пам'ять, «вентиль забування» вирішує, до якої міри значення буде збережено у пам'яті. «Вихідний вентиль» відповідає за те, як саме значення у пам'яті використовується при розрахунку вихідної функції активації для блоку[11].

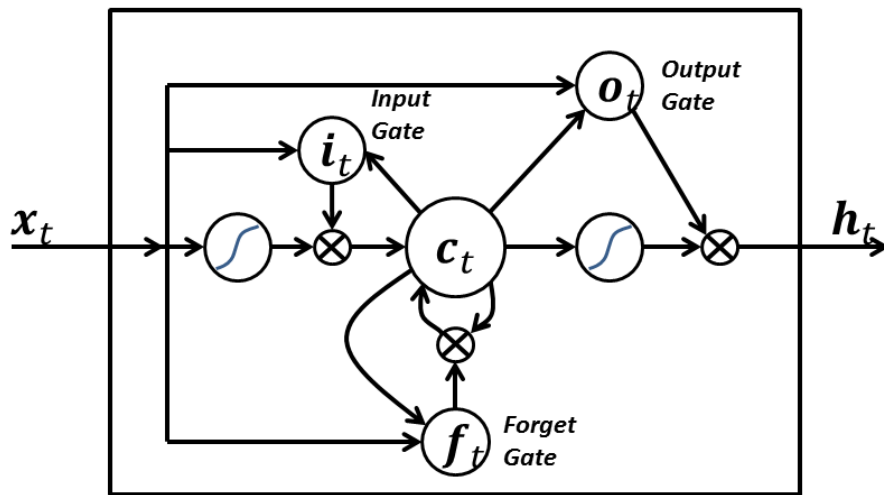


Рисунок 2.2 – Модель LSTM-блоку з трьома вентилями

LSTM-мережа добре пристосована до навчання на задачах класифікації, обробки і прогнозування часових рядів.

3.3.3 Згорткова нейронна мережа

Крім рекурентних нейронних мереж для прогнозування часових рядів можна використовувати згорткові нейронні мережі завдяки їх здатності до згортання

параметрів, вилучення ознак з локальних вхідних шаблонів, отримання ефективних і модульних уявлень даних, незважаючи на те, що основна сфера їх застосування – розпізнавання образів на зображеннях. Час також можна розглядати як просторовий вимір, подібно висоті або ширині двовимірного зображення.

У даній нейронній мережі в операції згортки використовується обмежена матриця ваг невеликого розміру. Її «рухають» послідовно по оброблюваному шару, формуючи після кожного зсуву сигнал активації для нейрона наступного шару з аналогічною позицією (див. рис. 2.3). Отже, одна і та ж матриця ваг, її також називають ядром згортки, використовуються для різних нейронів вихідного шару. А наступний шар, що вийшов в результаті операції згортки такою матрицею ваг, показує наявність даної ознаки в оброблюваному шарі і її координати, формуючи так звану карту.

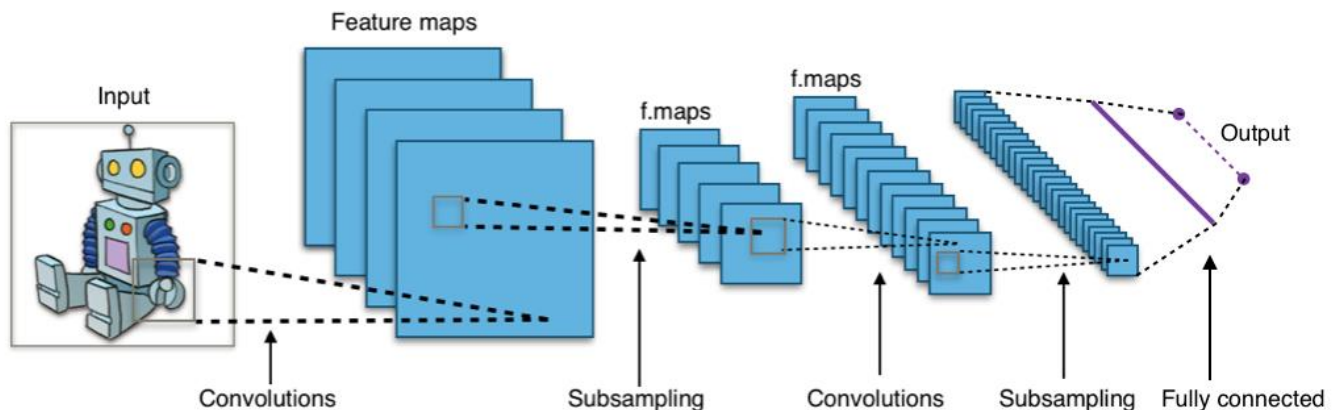


Рисунок 2.3 – Архітектура згорткової нейронної мережі

Завдяки тому, що кожним набором ваг прохід формує свій власний примірник карти ознак, нейронну мережа є багатоканальною (на одному шарі – багато незалежних карт ознак). Важливо зауважити, що у процесі перебору шару матрицею ваг її пересувають як правило не на повний крок (розмір цієї матриці), а на невелику відстань[12].

Роботу згорткової нейронної мережі можна описати як перехід від конкретних особливостей об'єкта до більш абстрактних деталей, і далі до ще більш абстрактних деталей і до виділення понять високого рівня. Також мережа здатна налаштовуватися самостійно і сама виробляти необхідну ієрархію абстрактних ознак (послідовності карт ознак), фільтруючи незначні деталі і виділяючи тільки важливе[13].

Навчанням штучної нейронної мережі називається процес підстроювання значень ваг зв'язків між нейронами мережі. У даній мережі використовується навчання з учителем, що припускає використання навчальної вибірки для порівняння вихідного сигналу мережі з еталонним значенням навчальної вибірки, розрахунок помилки і підстроювання ваг зв'язків мережі з метою зменшення значення цієї помилки. У якості алгоритму навчання використовується алгоритм градієнтного спуску або зворотного поширення помилки і його модифікації.

3. ПРОВЕДЕННЯ ДОСЛІДЖЕННЯ

3.1 Підготовка до експерименту

Для дослідження був вибраний датасет з вимірами середньої місячної температури останніх 270 років (з 1745 по 2015 року) у столицях 180 країн та територіальних утворень. Усього датасет містить 577 500 записів. Для кожної країни кількість вимірів складає приблизно 3500 за вказані роки.

Дані представлені у форматі csv і включають стовпці дати у форматі YYYY-MM-DD, температури і назви країни. Приклад даних для країни Австрії наведено на рисунку 3.1.

A	B	C
1754-01-01	-5.543	Austria
1754-02-01	-5.356	Austria
1754-03-01	-1.588	Austria
1754-04-01	6.129	Austria
1754-05-01	11.937	Austria
1754-06-01	15.176	Austria
1754-07-01	15.275	Austria
1754-08-01	15.595	Austria
1754-09-01	11.576	Austria

Рисунок 3.1 – Приклад вимірів температури для Австрії 1754 року

Навчання моделі буде окремим для кожної країни, так як на процеси на територіальній одиниці можуть залежати від різних наборів факторів та закономірностей. Отже, для кожної країни датасет буде розділено на дві частини: 1750 для тренувального набору та 1750 для тестувального набору.

Класичний процес для data science дослідження складається з таких етапів:

– збір даних, щоб забезпечити набір необхідних властивостей;

- попередня обробка даних перед їх використанням;
- розробка і реалізація моделі – вибір типу нейронної мережі і її параметрів;
- тестування на історичних даних;
- оптимізація – пошук відповідних параметрів.

Для проведення дослідження була обрана мова програмування Python. Вона відноситься до класу інтерпретованих мов програмування, що дозволяє значно спростити процес відлагодження програм. Python має величезну кількість модулів, як входять в стандартний пакет Python 3, так і сторонніх. У деяких випадках для написання програми достатньо знайти необхідні модулі і правильно їх скомбінувати. Таким чином, є можливість планувати програми на більш високому рівні, працюючи з уже готовими елементами, які реалізують різноманітні функції.

Крім цього, програма, написана на Python, буде функціонувати абсолютно однаково незалежно від того, в якій операційній системі вона запущена. Відмінності виникають лише в рідких випадках, і їх легко заздалегідь передбачити завдяки наявності докладної документації.

У якості основної бібліотеки буде використана Keras. Це проста у використанні API для створення нейронних мереж. Дана бібліотека містить реалізації широко застосовуваних будівельних блоків нейронних мереж, таких як шари, оптимізатори, і безліч інструментів для спрощення роботи з зображеннями, текстом та іншими даними. Модель нейронної мережі можна побудувати за допомогою всього декількох рядків коду.

Keras являє собою надбудову над декількома фреймворками, включаючи TensorFlow. Обчислення TensorFlow виражаються у вигляді потоків даних через граф станів. Назва бібліотеки походить від операцій з багатовимірними масивами даних, які також називаються «тензорами»[14]. За її допомогою планується створення згорткової нейронної мережі.

Крім цього, знадобляться інструменти для обробки та управління даними та структурами даних. NumPy бібліотека була використана для роботи з масивами,

матрицями та функціями для них. Pandas – одна з найпопулярніших Python бібліотек, що необхідна для маніпуляції та обробки чисельними таблицями та числовими рядами.

Необхідно наголосити, що велику роль грає використання чистих вхідних даних для дослідження прогнозування. Так як при виявленні недостатньої кількості шаблонів нейронна мережа не може якісно передбачити дані. Таким чином, необхідно ретельно ці дані обробити. Нормалізація даних необхідна, щоб зробити нашу модель більш ефективною. У якості однієї з допоміжних бібліотек для даних цілей була використана SciPy.

Для побудови графіків була використана бібліотека Matplotlib, що має об'єктно-орієнтований API для вбудовування графіків у додатки.

Після того, як необхідні бібліотеки підключені до проекту, необхідно прописати деякі глобальні константи та параметри для подальшої роботи прогнозування даних. Для початкового налаштування необхідно встановити `n_timestamp`, що позначає кількість днів, які будуть використовуватися як вхідні дані для прогнозування. Це важливо, оскільки необхідно розглянути, скільки даних повинна перевірити наша модель перед тим, як робити прогноз.

Також маємо тут `train_days` – кількість навчальних днів. Це гарантує, що модель засвоює декілька шаблонів на основі історичних даних. Змінна `testing_days` – це скільки днів ми хочемо передбачити. Для навчання ми маємо `n_epochs` – кількість епох, необхідних для навчання. Близько 40 епох було достатньо, щоб навчити модель без зайвого обговорення.

Як було зазначено раніше, обов'язковим етапом є нормалізація даних. На зразку коду нижче виконано медіанний фільтр та фільтр Гауса на наборі даних.

```
dataset['Temperature'] =
medfilt(dataset['Temperature'], 3)
dataset['Temperature'] = gaussian_filter1d(dataset['Temperature'], 1.2)
```

Фільтр Гауса визначає розподіл ймовірностей для шуму або даних. Він згладжує дані, згортаючи їх 3D-функцією Гауса. Це покращує співвідношення сигнал / шум.

Другим параметром до цієї функції передається стандартне σ , що є відхиленням для двовимірного ядра, а саме: радіус у пікселях, що містить 68% інтегральної величини коефіцієнтів.

Медіанний фільтр – це нелінійна цифрова техніка фільтрації, яка часто використовується для видалення шуму із зображення або сигналу. Таке зменшення шуму є типовим етапом попередньої обробки для поліпшення результатів подальшої обробки. Другий параметр до функції `kernel_size` визначає розмір вікна фільтра.

Наступним кроком необхідно нормалізувати дані і привести їх до вигляду від 0 до 1. Набір даних потрібно розділити відповідно до кількості відміток часу. Код для здійснення даної операції за допомогою `MinMaxScaler` наведено нижче.

```
sc = MinMaxScaler(feature_range = (0, 1))
training_set_scaled = sc.fit_transform(training_set)
testing_set_scaled = sc.fit_transform(testing_set)
```

Після того, як дані про середньомісячну температуру зібрані, відфільтровані та нормалізовані, можна переходити до розробки моделей з обраними архітектурами.

3.2 Використання MLP архітектури

MLP – найпростіша форма нейронних мереж. Вхідні дані потрапляють в модель і за допомогою певних вагів значення передаються через приховані шари для отримання вихідних даних. Навчання алгоритму походить від зворотного поширення через приховані шари, щоб змінити значення ваг кожного нейрона.

Для імплементації MLP за допомогою Keras реалізуємо просту сітку – вхідний шар з 30 нейронами (довжина нашого вікна), перший прихований шар з 64 нейронами. Після нього необхідно застосувати `BatchNormalization` – його рекомендується використовувати практично для будь-яких багатошарових мереж, а потім функція

активації LeakyReLU. На виході розмістимо один нейрон, як представлено на фрагменті коду нижче.

```
# Define MLP
model = Sequential()
model.add(Dense(64, input_dim=30))
model.add(BatchNormalization())
model.add(LeakyReLU())
model.add(Dense(1))
model.add(Activation('softmax'))
```

Далі потрібно визначити функції помилки і алгоритм оптимізації. Для оптимізації цільової функції за допомогою градієнтного спуску візьмемо оптимізаційний алгоритм Adam з довжиною кроку 0.001. Як параметр loss для класифікації потрібно поставити крос-ентропію – categorical_crossentropy.

Також Keras дозволяє досить гнучко контролювати процес навчання, наприклад, зменшувати значення кроку градієнтного спуску, якщо наші результати не поліпшуються – саме для цього потрібна функція ReduceLROnPlateau, яка передана як коллбек в навчання моделі. Описаний алгоритм ілюструється кодом нижче.

```
reduce_lr = ReduceLROnPlateau(monitor='val_loss', factor=0.9,
patience=5, min_lr=0.000001, verbose=1)
model.compile(optimizer=opt, loss='categorical_crossentropy',
metrics=['accuracy'])
# Start training
history = model.fit(X_train, y_train, epochs = n_epochs, batch_size = 256,
verbose=1, validation_data=(X_test, Y_test), shuffle=True,
callbacks=[reduce_lr])
```

Важливим кроком на етапі тренування моделі є підбір кількості епох. Для початку було вибрано 20 епох. Кількість епох позначає кількість ітерацій по даним. Було вказано 256 батчів. Батч – це пакет даних, так званий зразок.

Після того, як закінчилось навчання, відбувається вимірювання точності і втрат моделі за допомогою тестувального набору даних.

Після отримання перших результатів, було прийнято рішення збільшити кількість епох до 40. За результатами отриманих параметрів loss і асс, саме цієї кількості виявилось достатньо для того, щоб навчити модель, але в цей же час не перетренувати її.

Отримуємо результати параметрів на останній епохі (див. рис. 3.2.) Тут `loss` – відсоток втрат. Чим він нижче, тим менше було неточних передбачень. `val_loss` – значення функції втрат для даних перехресної перевірки.

```
loss: 0.1962 - accuracy: 0.9418 - val_loss: 0.1720 - val_accuracy: 0.9459
```

Рисунок 3.2 – Точності і втрати моделі на 40 епохі

Також важливо відслідковувати значення асигасу (точність даних навчання) і `val_асигасу` (точність даних перевірки) з плином епох. Зобразимо на графіку відношення асигасу до епох (див. рис. 3.3).




Рисунок 3.3 – Відношення точності даних навчання до епох

Наприклад, якщо асигасу продовжує поліпшуватися, а `val_асигасу` погіршується, то відбувається перенавчання. Навчання повинно бути припинено, коли `val_асигасу` перестає збільшуватися.

3.3 Використання LSTM архітектури

Для експерименту була обрана складена LSTM модель. Стандартна модель LSTM складається з одного прихованого шару LSTM, за яким йде вихідний шар з прямим зв'язком. Складена модель – це розширення стандартної моделі, що має кілька прихованих шарів LSTM, де кожен шар містить кілька осередків пам'яті. Складену архітектуру LSTM можна визначити як модель LSTM, що складається з декількох шарів. Кожен шар надає вихід послідовності, а не одне значення, що виводиться на рівень шару нижче.

Збільшення глибини мережі надає альтернативне рішення, що потребує менше нейронів і навчається швидше. Також, глибоке навчання будується навколо гіпотези про те, що глибока ієрархічна модель може бути експоненціально більш ефективна для подання деяких функцій, ніж поверхнева [15]. Тобто, додавання глибини – це оптимізація.

З огляду на те, що LSTM працює з даними послідовності, це означає, що додавання шарів додає рівні абстракції вхідних спостережень у часі. Глибина мережі є більш важливою, ніж кількість елементів пам'яті в даному шарі для моделювання навичок навчання. У даному експерименті буде використовуватися складена модель, у якій два шари LSTM складені разом.

Після того, як дані були згруповані за структурою, необхідною для даної моделі, переходимо до створення LSTM за допомогою Keras:

```
# Define Stacked LSTM
model = Sequential()
model.add(LSTM(50, activation='relu', return_sequences=True,
input_shape=(X_train.shape[1], 1)))
model.add(LSTM(50, activation='relu'))
model.add(Dense(1))
```

Навчання моделі показано на фрагменті коду нижче:

```
# Start training
```

```

model.compile(optimizer = 'adam', loss = 'mean_squared_error')
history = model.fit(X_train, y_train,
epochs = n_epochs,
batch_size = 256)
loss = history.history['loss']
epochs = range(len(loss))

```

Для наочності побудуємо графік прогнозу на наступні 75 місяців (трохи більше, ніж 3 роки).




Рисунок 3.4 – Прогнозування температури на 75 місяців

Побудуємо також графік прогнозування для наступних 500 місяців – майже 21 рік (див. рис. 3.5).

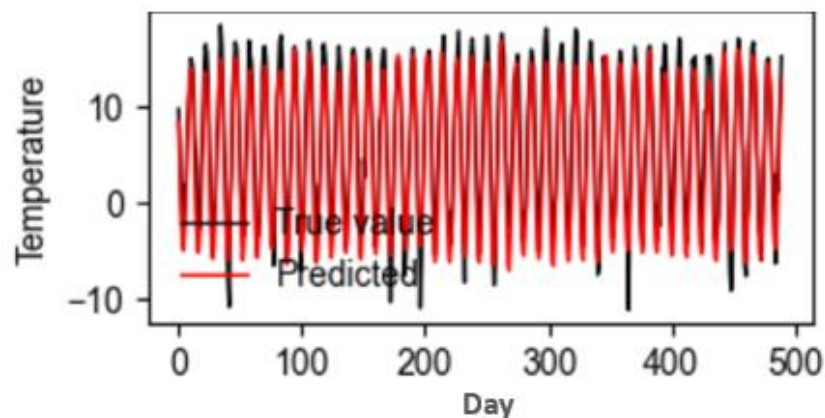


Рисунок 3.5 – Прогнозування температури на 500 місяців

За результатами прогнозування моделі було успішним. Однак із передбачуваних 500 місяців можна помітити, що помилки, як правило, зумовлені несподіваним

зростанням або спадом даних, наприклад, у місяці 180 та 360. Але, виходячи з перших 75 місяців, модель може правильно слідувати шаблону даних.

Для вибору оптимальної кількості епох також були проведені експерименти з їх кількістю, аналогічно до попередньої моделі. Найоптимальнішою кількістю виявилось 50 епох для даної моделі при значеннях $\text{loss} = 0.23$, $\text{accuracy} = 0.91$, $\text{val_loss} = 0.207$, $\text{val_accuracy} = 0.8813$.

3.4 Використання CNN архітектури

Традиційно розроблені для даних двовимірного зображення, згорткові нейронні мережі можуть використовуватися для моделювання одновимірних задач прогнозування часових рядів. Наші дані про заміри температури є одновимірним часовим рядом. Даний ряд можна описати як набори даних, що складаються з однієї серії спостережень з тимчасовим упорядкуванням, де потрібна модель, отримати шаблони із серії минулих спостережень для передбачення наступного значення в послідовності.

Перш ніж можна змоделювати одновимірний ряд для згорткової нейронної мережі, він повинен бути окремо підготовлений. Ми можемо розділити послідовність на кілька вибірок введення / виведення, де три часових кроки використовуються в якості вхідних даних, а один часовий крок використовується в якості вихідних даних для досліджуваного однокрокового передбачення[16].

Для даного експерименту була вибрана одновимірна згорткова нейронна мережа – це модель CNN, яка має прихований згортковий шар, що працює над одновимірною послідовністю. Для дуже довгих послідовностей як наша, після першого шару може йти другий згортковий шар, завдання якого полягає в тому, щоб виділити з результату першого шару найбільш помітні елементи.

Після згорткового та об'єднуючого шарів йде щільний повністю зв'язаний шар, який інтерпретує особливості, що були отримані попередньою частиною моделі. Між згортковим шаром і щільним шаром використовується так званий згладжений шар, щоб звести карти об'єктів до одного одновимірного вектору.

На коді нижче представлено визначення 1D моделі CNN для одновимірного прогнозування часових рядів.

```
# Define CNN
model = Sequential()
model.add(Dense(64, input_dim=30, activity_regularizer=regularizers.l2(0.01)))
model.add(BatchNormalization())
model.add(LeakyReLU())
model.add(Dropout(0.5))
model.add(Dense(16, activity_regularizer=regularizers.l2(0.01)))
model.add(BatchNormalization())
model.add(LeakyReLU())
model.add(Dense(1))
model.add(Activation('softmax'))
```

У визначенні моделі ключовим є форма введення – це те, що модель очікує в якості вхідних даних для кожної вибірки з точки зору кількості часових кроків і кількості функцій. Ми працюємо з одновимірним рядом, тому число функцій дорівнює одній для однієї змінної.

Число тимчасових кроків в якості вхідних даних – це число, яке ми вибрали при підготовці набору даних, в даному випадку воно дорівнює трьом.

У коді визначено згортковий шар з 64 картами фільтрів і розміром ядра 2. Потім йде шар максимального пулу і щільний шар для інтерпретації вхідного об'єкта. Вказано вихідний шар, який передбачає одне числове значення.

Дана модель виявилася найскладнішою з усіх на етапі налаштування. При першому тестуванні спостерігався ефект зменшення помилки, при цьому без зменшення точності. Можна припустити, що дані були подекуди зашумлені. Це пояснюється тим, що помилка вважається на основі значення cross-entropy, яке може зменшуватися під час того, як точність – це індекс нейрона з правильною відповіддю, який навіть при зміні помилки може залишатися неправильним.

Тому модель була багато разів модифікована, зокрема додаванням регуляризації за допомогою популярної в останні роки техніки Dropout. Це випадкове «ігнорування» деяких ваг в процесі навчання, щоб уникнути ко-адаптації нейронів (щоб вони не вивчали однакові ознаки).

Варто зауважити, CNN фактично не розглядає дані у якості часових кроки, замість цього модель обробляє дані як послідовність, над якою можуть виконуватися згорткові операції читання так само, як на одномірному зображенні[17].

Як тільки модель визначена, починаємо навчання, код для якого зображено нижче.

```
# Start training
model.compile(optimizer='adam', loss='mse')
model.fit(X_test, y_test, epochs = n_epochs, verbose=0)
```

Модель використовує стохастичний градієнтний спуск adam, оптимізований з використанням середньоквадратичної помилки – mse.

Результат для прогнозування для 75 місяців представлений на рисунку 3.6.




Рисунок 3.4 – Прогнозування температури на 75 місяців

Найбільш вдалим числом епох для моделі стало 60. З графіку видно, що прогнозовані дані не так вдало описують поведінку реальних значень. При значеннях $loss = 0.438$, $accuracy = 0.8256$, $val_loss = 0.334$, $val_accuracy = 0.794$ був зафіксований момент, коли модель ще не досягла точки перенавчання і вибрана кількість епох.

Побудуємо графік передбачень для періоду часу 500 місяців (див. рис. 3.5).

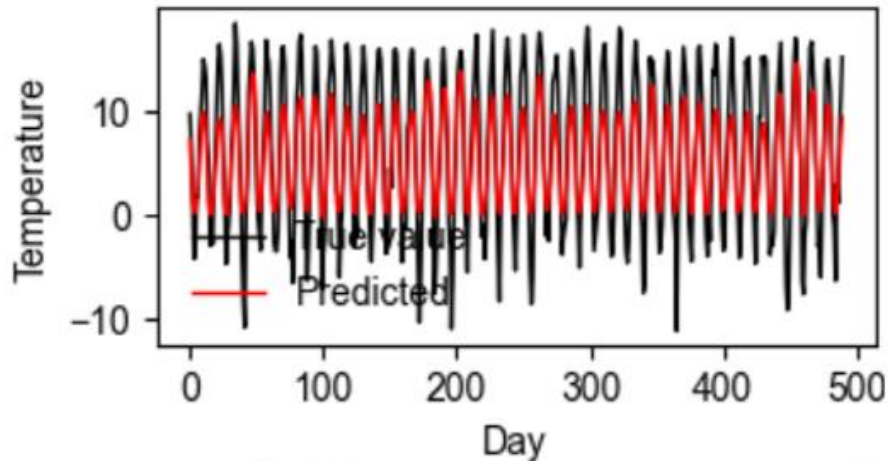


Рисунок 3.5 – Прогнозування температури на 500 місяців

На відрізку часу близько 21 року модель показує недостатньо точні результати. Можна зробити висновок, що вона не підходить для створення довгострокових прогнозів температури.

Можливо, для даного типу архітектури необхідна більша кількість даних або необхідно оптимізувати параметри – розмір вікна, кількість нейронів в прихованих шарах, крок навчання. Дані параметри були взяті з урахуванням середніх величин, що зазвичай використовують при прогнозуванні часових рядів.

3.5 Оцінка результатів у веб-додатку

Веб-додаток було створено за допомогою бібліотеки ReactJS. Це бібліотека з відкритим кодом на JavaScript для побудови користувацьких інтерфейсів або компонентів інтерфейсу. React можна використовувати як основу при розробці single-page веб або мобільних додатків.

Додаток містить інтерфейс для вибору країни та року для прогнозу температурних показників. Необхідно вибрати країну та рік, за який необхідно отримати прогноз, через dropdown і натиснути кнопку «Forecast», щоб побачити результати передбачення температури у столиці даної країни по місяцям вказаного року (див. рис. 3.6). Для вибору доступні роки, починаючи з 2021 і до 2071 – на найближчі 50 років.

Choose country and year to predict temperature

Country: Austria, Vienna Year: 2028 **FORECAST**

Foresast in °C for Austria, Vienna. 2028 year

Model	Jan	Feb	Mar	Apr	May	Jun	Jul	Aug	Sept	Oct	Nov	Dec
MLP	-7	-4	8	16	18	22	28	30	20	21	18	10
MSLT	-6	-4	11	19	20	23	24	28	17	17	16	6
CNN	0	-9	6	17	20	19	23	25	21	18	14	2

Рисунок 3.6 – Інтерфейс веб-додатку для прогнозу погоди

У результаті роботи передбачення користувач отримуватиме результати передбачення кожною з моделей – MLP, MSLT та CNN. Виконаємо результати прогнозу для п'яти країн – України, Австрії, Австралії, Канади та Бразилії.

Для кожної країни була створена окрема модель для прогнозу температури саме на території її столиці країни, але було б доцільно провести експеримент щодо передбачення температури різних країн одною і тією ж моделлю. Тому, у якості виключення для прогнозу у Бразилії будемо використовувати модель, що була

створена для Австрії. На таблиці 3.1 представлено порівняння точності передбачень – асигасу – на тестових даних різних країн і датасетів.

Таблиця 3.1 – Результати експерименту для різних країн і датасетів

Країна	Датасет	MLP	LSTM	CNN
Україна	Україна	0.92	0.92	0.81
Австралія	Австралія	0.89	0.9	0.79
Канада	Канада	0.88	0.94	0.75
Австрія	Австрія	0.94	0.91	0.82
Бразилія	Австрія	0.84	0.86	0.7

За результатами тестування можна відразу помітити, що датасет Австралії дає непогані результати для країни Австралії, але для даних по країні Бразилії дає незадовільну точність прогнозу. Тобто, модель краще дає передбачення на даних, на яких вона навчалась. Це пояснюється тим, що дійсно, у кожній країні відбуваються несхожі один на одну погодні процеси. Також фактори, що впливають на температуру повітря на перший погляд можуть бути схожими, але все-таки відрізняються один від одного у різних точках світу.

Щодо інших датасетів та видів архітектур, модель CNN показує найгірші результати за точністю. MLP має задовільні результати і модель LSTM рекомендує себе як більш точну. Пояснення результатам може впливати з призначення кожної з досліджуваних архітектур. Не дарма існує широкий ряд архітектур нейронних мереж – кожна створювалась вирішення актуальних задач. CNN більш успішно зарекомендувала себе у розпізнаванні та класифікації графічних даних. MLP та LSTM краще підходять у випадках прогнозування часових рядів.

ВИСНОВКИ

На сьогоднішній день найбільш популярні методи прогнозування погоди – синоптичний, численний, статистичний – дають задовільну точність у короткочасних умовах, але їм не можна вважати надійною і тим більше точною для довгострокових прогнозів погодних умов. Дані методи працюють на базі спрощених математичних функцій, де певна кількість параметрів опущена або огрублена. Саме це не дає прогнозу бути повністю правдивим.

Нейронні мережі зарекомендували себе як потужний інструмент у різноманітних областях, особливо там, де потрібне застосування людського інтелекту, у тому числі і аналізу часових рядів. Так як нейронні мережі добре вирішують задачі моделювання нелінійної залежності майбутнього значення часового ряду від його минулих значень і від значень зовнішніх факторів, дана технологія може бути надзвичайно цікавою для дослідження саме у контексті прогнозування метеорологічних явищ.

Важливість знання погоди важко переоцінити – людські життя залежать від дії суспільства в умовах стихійних лих і різких змін кліматичних явищ. Сільське і лісове господарства, судноплавство, авіація, енергетична область, торговий сектор використовують актуальну інформацію про стан погоди кожен день, щоб корегувати свої плани для отримання максимальної вигоди і мінімальних збитків для себе.

Ми та все, що нас оточує, існує у атмосфері нашої планети, а її параметри у свою чергу змінюється під впливом метеорологічних явищ. Отже, кожен із нас так чи інакше приймає різноманітні рішення кожен день в залежності від стану погоди.

На побутовому рівні погодні умови також здатні вплинути на життя звичайної людини – від вибору одягу до вжиття заходів щодо стану здоров'я.

Отже, прогнозування погодних умов є достатньо складною і актуальною задачею, особливо в довгострокових періодах. Нейронні мережі обіцяють стати кращим помічником у цій області.

У результаті роботи були проаналізовані популярні архітектури нейронних мереж: багат шаровий перцептрон Румельхарта, згорткова та рекурентна нейронні мережі. Кожна з них по-своєму підходить до задач вирішення задачі прогнозування числових рядів.

Згорткова нейронна мережа показує найгірші результати точності для наших даних. Існує декілька пояснень цього явища. Можливо, модель дійсно потребує більш ретельного налаштування параметрів для покращення своєї точності. Проте, аргумент у користь того, що дана архітектура не так добре підходить для прогнозування числових рядів також має місце.

За результатами експерименту найвищу точність показала модель з рекурентною архітектурою нейронної мережі. Повнозв'язна нейронна мережа прямого поширення мала задовільну точність. Загалом подібні архітектури дуже добре підходять до задач прогнозування часових послідовностей.

Отже, у даному дослідженні було виявлено, що LSTM є хорошим інструментом для прогнозування даних. Однак є моменти, які можна покращити у даному рішенні. По-перше, збільшення кількості введених днів не означає, що модель буде більш точною. Крім цього, кондиціонування даних може допомогти зробити модель точніше[18]. Процес тренування моделі можливо також краще налаштувати ще краще.

Також можливим сценарієм для подальшої роботи з моделлю може бути створення веб-застосунку для аналітики тенденції глобального потепління.

ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ

1. Матвеев Л.Т. Курс общей метеорологии. Физика атмосферы. JL: Гидрометеоиздат, 1976. – 677 с.
2. Бокс Дж, Дженкинс Г. Анализ временных рядов. Прогноз и управление. М.: Мир, Вып.1, Вып.2., 1974. – 532 с
3. Neural Network Load Forecasting with Weather Ensemble Predictions. James W. Taylor and Roberto Buizza IEEE Trans. on Power Systems, 2002, Vol. 17, P. 626-632.
4. Imran Maqsood, Muhammad Riaz Khan, Ajith Abraham – An ensemble of neural networks for weather forecasting. Neural Comput & Applic (2004) 13: 112–122 DOI 10.1007/s00521-004-0413-4 © Springer-Verlag London Limited 2004. – 464p.
5. Григорьева Д.Р. Методы статистического прогнозирования // Экономический анализ: теория и практика. – 2015 . – №17. – С. 21-23
6. Хайкин, С. Нейронные сети: полный курс / С. Хайкин. – М.: Диалектика, 2019. – 1104 с.
7. A Brief Introduction to Neural Networks / D. Kriesel. URL: http://www.dkriesel.com/en/science/neural_networks (дата звернення: 16.02.2021).
8. Прогноз погоды / ПостНаука. URL: <https://postnauka.ru/> (дата звернення: 19.02.2021).
9. Шолле Ф. Глубокое обучение на Python. – СПб.: Питер, 2018.
10. Антоніо Джуллі, Суджит Пал. Библиотека Keras – инструмент глубокого обучения. – М.: ДМК Пресс, 2018. – 294 с.
11. Miljanovic M. Comparative analysis of Recurrent and Finite Impulse Response Neural Networks in Time Series Prediction // Indian Journal of Computer Science and Engineering (IJCSE). – 2012 V. 3 N. 1 – P. 180–191

12. Miljanovic M. Comparative analysis of Recurrent and Finite Impulse Response Neural Networks in Time Series Prediction // Indian Journal of Computer Science and Engineering (IJCSE). – 2012 V. 3 N. 1 – P. 180 –191

13. Редько, В.Г. Эволюция, нейронные сети, интеллект: Модели и концепции эволюционной кибернетики / В.Г. Редько. – Москва: СИНТЕГ, 2017. – 224 с

14. Kirill Smelyakov, Dmytro Yeremenko, Anton Sakhon, Vitalii Polezhai, Anastasiya Chupryna. Braille character recognition based on neural networks // IEEE Second International Conference on Data Stream Mining & Processing (DSMP), August 21-25. – 2018. – P. 509-513.

15. Maksym Bekuzarov, Oleksandr Samantsov, Oksana Mazurova, Mariia Shirokopetleva. Neural Network Architecture Editor With Code Generation. Problem of Infocommunications. Science and Technology (PIC S&T'2020), Kharkiv, Ukraine.- 6-9 October 2020.

16. Smelyakov K., Chupryna A., Bohomolov O., Ruban I. The Neural Network Technologies Effectiveness for Face Detection // IEEE Third International Conference on Data Stream Mining & Processing (DSMP), August 21-25. – 2020. – P. 201-205.

17. Andrey Arsenov, Igor Ruban, Kyrylo Smelyakov, Anastasiya Chupryna. Evolution of Convolutional Neural Network Architecture in Image Classification Problems Selected Papers of the XVIII International Scientific and Practical Conference on IT and Security (ITS 2018).–CEUR Workshop Processing 11 Andrey Arsenov, Igor Ruban, Kyrylo Smelyakov, Anastasiya Chupryna.

18. Marharyta Manachenko. Time series forecasting with LSTM neural network // IEEE VII International Scientific and Practical Conference. International Forum: Problems and Scientific Solutions. April 25-26. – 2021. – P. 696-698.