

Хмельницький національний університет
Факультет інформаційних технологій
Кафедра комп'ютерних наук

КВАЛІФІКАЦІЙНА РОБОТА МАГІСТРА

на тему Метод прогнозування забруднення доріг на основі підходу
глибокого активного навчання

Галузь знань 12 – Інформаційні технології
Шифр і назва галузі знань

Спеціальність 122 – Комп'ютерні науки
Шифр і назва спеціальності

Освітня програма Комп'ютерні науки
Назва освітньої програми

Виконав: студент 2 курсу, група КНм-22-1
курс, група виконавця


Підпис

Д.В. Смоленко

Ініціали, прізвище


Керівник: к.п.н., доцент кафедри КН
Науковий ступінь, посада


Підпис

С.С. Петровський

Ініціали, прізвище

Нормконтроль: к.п.н., доцент кафедри КН
Науковий ступінь, посада


Підпис

Р.О. Багрій

Ініціали, прізвище

До захисту допускаю:

Зав. кафедри КН, д.т.н., професор


Підпис

О.В. Бармак

Ініціали, прізвище

7 12 2023 р.

ХМЕЛЬНИЦЬКИЙ НАЦІОНАЛЬНИЙ УНІВЕРСИТЕТ

Факультет інформаційних технологій

Кафедра комп'ютерних наук

Освітній ступінь магістр

Галузь знань 12 – Інформаційні технології

Спеціальність 122 – Комп'ютерні науки

ЗАТВЕРДЖУЮ

Завідувач кафедри комп'ютерних наук


(підпис)

д.т.н., професор О.В. Бармак

« 01 » вересня 2023 року

**ЗАВДАННЯ
НА КВАЛІФІКАЦІЙНУ РОБОТУ МАГІСТРА**

1. Тема кваліфікаційної роботи магістра: Метод прогнозування забруднення доріг на основі підходу глибокого активного навчання
2. Завдання видано студенту Смолієнку Данилу Валентиновичу
(прізвище, ім'я, по батькові)
3. Керівник роботи к.п.н. доцент кафедри КН Петровський Сергій Степанович
(прізвище, ім'я, по батькові)
4. Затверджені наказом університету віз « 15 » липня 2023 р. № 30
5. Зміст пояснювальної записки (перелік задач) та вихідні дані:
Метою кваліфікаційної роботи магістра є розробка методу прогнозування забруднення доріг на основі підходу глибокого активного навчання з використанням зображень. Для досягнення поставленої мети потрібно виконати наступні завдання: дослідити предметну область та вивчити методи реалізації подібних задач, зробити аналіз моделей та методів прогнозування забруднення доріг, розробити метод прогнозування забруднення доріг, розробити програмне забезпечення розробленого методу, провести експерименти та проаналізувати ефективність.

Реферат

Кваліфікаційна робота магістра присвячена розробці методу прогнозування забруднення доріг на основі підходу глибокого активного навчання.

Актуальність теми. Прогнозування забруднення доріг на основі підходу глибокого активного навчання має велику актуальність в сучасному світі. Забруднення доріг стає серйозною проблемою в багатьох містах, і вирішення цього питання може принести позитивний вплив на якість життя місцевого населення та збереження навколишнього середовища. Нижче приведені кілька аспектів, які підкреслюють актуальність цієї теми.

1. Охорона здоров'я: Забруднення доріг може впливати на здоров'я мешканців міста через викиди токсичних речовин. Розробка ефективного методу прогнозування може допомогти управлінню та зменшенню забруднення, забезпечуючи більш чисте довкілля для громадян.

2. Сталість інфраструктури: Забруднення може впливати на стан інфраструктури, такої як дороги та мости. Прогнозування забруднення може допомогти уникнути пошкоджень і забезпечити більш довговічність інфраструктури.

3. Ефективне управління ресурсами: Забруднення доріг вимагає великої кількості ресурсів для його очищення та управління. Застосування методів глибокого активного навчання для прогнозування дозволить більш ефективно розподіляти ресурси і здійснювати дієве управління забрудненням.

4. Розвиток технологій: Використання глибокого активного навчання для прогнозування забруднення доріг відображає розвиток сучасних технологій в галузі штучного інтелекту та машинного навчання.

5. Сталий розвиток: Зменшення забруднення може сприяти сталому розвитку, оскільки це покращить якість життя та сприятиме збереженню природних ресурсів.

Доцільно провести дослідження та впровадити практичні заходи для розробки методу прогнозування забруднення доріг, яка базується на

глибокому активному навчанні, зокрема використовуючи дані сенсорів, IoT-технології та інші джерела інформації для забезпечення точності та ефективності прогнозування.

Таким чином розробка методу прогнозування забруднення доріг є досить актуальною.

Мета і задачі роботи. Метою кваліфікаційної роботи магістра є розробка методу прогнозування забруднення доріг на основі підходу глибокого активного навчання з використанням зображень. Для досягнення поставленої мети потрібно виконати наступні завдання:

- провести аналіз предметної області, математичних моделей, нейромережевих моделей, що можуть бути використані для прогнозування забруднення доріг.

- розробити метод прогнозування забрудненості доріг на основі підходу глибокого активного навчання.

- вдосконалити нейромережеву модель визначення рівня забрудненості доріг.

- навчити нейронну мережу здійснювати прогноз забруднення дороги із ряду зображень.

- провести дослідження ефективності методу прогнозування забруднення доріг з підходом глибокого активного навчання, визначити точність роботи такого методу.

Об'єкт дослідження - процес прогнозування забруднення доріг на основі підходу глибокого активного навчання.

Предмет дослідження – методи прогнозування забруднення доріг, моделі нейронної мережі для визначення забрудненості та здійснення прогнозу.

Методи дослідження, використані для виконання поставлених завдань: для виявлення забрудненості – вдосконалена нейронна мережа CNN та LSTM; для прогнозування забруднення доріг – нейронна мережа LSTM, в поєднанні з CNN та повнозв'язними шарами.

Наукова новизна одержаних результатів. В результаті роботи були отримані наступні положення наукової новизни:

Запропоновано метод прогнозування забруднення доріг на основі підходу глибокого активного навчання. При розробці методу були застосовані глибокі нейронні мережі для підходу активного навчання, для аналізу та прогнозування забруднення доріг. Було адаптовано нейронну мережу до предметної області, а саме до розпізнавання забруднення доріг шляхом зміни гіперпараметрів, що в подальшому дозволяє прогнозувати рівень такого забруднення з зображень.

Вдосконалено нейромереві моделі для визначення рівня забрудненості доріг на зображенні та для прогнозування рівня забруднення. Було використано поєднання кращих особливостей декількох нейромеревих моделей – CNN, LSTM, повнозв'язних шарів, що дозволяє з високою точністю оцінити та отримати як результат рівень забрудненості дороги на зображенні у відсотках.

Апробація результатів кваліфікаційної роботи магістра та публікації. Основні наукові та практичні результати опубліковані у Збірник наукових праць за матеріалами XIV Всеукраїнської науково-практичної конференції «Актуальні проблеми комп'ютерних наук АПКН-2023». - Хмельницький, 2023. - С. 280-283 за темою роботи: Смолієнко Д. В., Петровський С.С., Метод прогнозування забруднення доріг на основі підходу глибокого активного навчання. Також, результати роботи опубліковані у науковому журналі – Метод прогнозування забруднення доріг на основі підходу глибокого активного навчання / Смолієнко Д.В., Петровський С.С // Науковий журнал «Вісник Хмельницького національного університету. Серія: Технічні науки» Хмельницький, 2023, №6 (Довідка з редакції).

Структура та обсяг роботи. Дипломна робота магістра складається з завдання, реферату, змісту, переліку скорочень, вступу, 4 розділів, висновків, переліку посилань із 40 найменувань та 2 додатків. Загальний обсяг дипломної роботи магістра становить 82 сторінки, з них 71 сторінка основного тексту та 11 сторінок додатків. У роботі наведено 22 рисунки.

Ключові слова: забруднення доріг, глибоке активне навчання, прогнозування, зображення, нейромереві, транспорт.

Зміст

Перелік скорочень	5
Вступ.....	6
Розділ 1 Сучасний стан методів прогнозування забрудненості доріг методами штучного інтелекту	9
1.1 Аналіз сфери прогнозування забрудненості доріг	9
1.2 Аналіз математичних моделей прогнозування забруднення доріг	12
1.3 Аналіз існуючих публікацій для прогнозування забрудненості доріг ..	14
1.4 Аналіз нейромережових моделей прогнозування забруднення доріг ...	17
1.5 Постановка задачі.....	22
Висновки до Розділу 1	23
Розділ 2 Методи для прогнозування забрудненості доріг на основі підходу глибокого активного навчання	24
2.1 Нейромережева модель для прогнозування забруднення доріг на основі підходу глибокого активного навчання	24
2.2 Підхід до збільшення розмірності вхідних даних для прогнозування забрудненості доріг на основі підходу глибокого активного навчання	29
2.3 Підхід до визначення рівня забруднення доріг на основі підходу глибокого активного навчання	33
2.4 Метод прогнозування забруднення доріг на основі глибокого активного навчання.....	36
Висновки до розділу 2.....	39
Розділ 3 Інформаційна система розробленого методу прогнозування забруднення доріг на основі підходу глибокого активного навчання	40
3.1 Модулі інформаційної системи прогнозування забруднення доріг	40
3.2 Компоненти модулів інформаційної системи прогнозування забруднення доріг.....	47

3.3 Проєктування програмних засобів для прогнозування забруднення доріг	49
Висновок до розділу 3	52
Розділ 4 Дослідження ефективності методу прогнозування забруднення доріг на основі підходу глибокого активного навчання.....	54
4.1 Створення датасету для дослідження ефективності методу	54
4.2 Дослідження ефективності методу прогнозування забруднення доріг на основі підходу глибокого активного навчання.....	57
4.3 Дослідження ефективності нейромережевої моделі визначення рівня забрудненості дороги на зображенні.....	60
4.4 Програмна реалізація модуля прогнозування забруднення доріг на основі підходу глибокого активного навчання.....	63
4.4.1 Програмна реалізація модуля збільшення розмірності вхідних даних за допомогою згорткових мереж і часових лагів	63
4.4.2 Програмна реалізація модуля визначення рівня забруднення доріг на основі підходу глибокого активного навчання	66
4.4.3 Програмна реалізація модуля прогнозування рівня забруднення доріг на основі підходу глибокого активного навчання	69
Висновки до розділу 4.....	71
Загальні висновки.....	73
Перелік джерел.....	77
ДОДАТКИ	

Перелік скорочень

Скорочення, термін, позначення	Пояснення
CNN	Convolutional Neural Network (Згорткові нейронні мережі)
RNN	Recurrent Neural Network (Рекурентні нейронні мережі)
MLP	Multilayer Perceptron (Багатошаровий перцептрон)
LSTM	Long Short-Term Memory (Довга короткочасна пам'ять)
RMSE	Root Mean Squared Error (Середньоквадратична Похибка)
MAE	Mean Absolute Error (Середня Абсолютна Помилка)

Вступ

Кваліфікаційна робота магістра присвячена розробці методу прогнозування забруднення доріг на основі підходу глибокого активного навчання.

Актуальність теми. Прогнозування забруднення доріг на основі підходу глибокого активного навчання має велику актуальність в сучасному світі. Забруднення доріг стає серйозною проблемою в багатьох містах, і вирішення цього питання може принести позитивний вплив на якість життя місцевого населення та збереження навколишнього середовища. Нижче наведено кілька аспектів, які підкреслюють актуальність цієї теми.

1. Охорона здоров'я: Забруднення доріг може впливати на здоров'я мешканців міста через викиди токсичних речовин. Розробка ефективного методу прогнозування може допомогти управлінню та зменшенню забруднення, забезпечуючи більш чисте довкілля для громадян.

2. Сталість інфраструктури: Забруднення може впливати на стан інфраструктури, такої як дороги та мости. Прогнозування забруднення може допомогти уникнути пошкоджень і забезпечити більш довговічність інфраструктури.

3. Ефективне управління ресурсами: Забруднення доріг вимагає великої кількості ресурсів для його очищення та управління. Застосування методів глибокого активного навчання для прогнозування дозволить більш ефективно розподіляти ресурси і здійснювати дієве управління забрудненням.

4. Розвиток технологій: Використання глибокого активного навчання для прогнозування забруднення доріг відображає розвиток сучасних технологій в галузі штучного інтелекту та машинного навчання.

5. Сталий розвиток: Зменшення забруднення може сприяти сталому розвитку, оскільки це покращить якість життя та сприятиме збереженню природних ресурсів.

Доцільно провести дослідження та впровадити практичні заходи для розробки методу прогнозування забруднення доріг, яка базується на глибокому активному

навчанні, зокрема використовуючи дані сенсорів, IoT-технології та інші джерела інформації для забезпечення точності та ефективності прогнозування.

Таким чином розробка методу прогнозування забруднення доріг є досить актуальною.

Мета і задачі роботи. Метою кваліфікаційної роботи магістра є розробка методу прогнозування забруднення доріг на основі підходу глибокого активного навчання з використанням зображень. Для досягнення поставленої мети потрібно виконати наступні завдання:

- провести аналіз предметної області, математичних моделей, нейромережових моделей, що можуть бути використані для прогнозування забруднення доріг.

- розробити метод прогнозування забрудненості доріг на основі підходу глибокого активного навчання.

- вдосконалити нейромережову модель визначення рівня забрудненості доріг.

- навчити нейронну мережу здійснювати прогноз забруднення дороги із ряду зображень.

- провести дослідження ефективності методу прогнозування забруднення доріг з підходом глибокого активного навчання, визначити точність роботи такого методу.

Об'єкт дослідження - процес прогнозування забруднення доріг на основі підходу глибокого активного навчання.

Предмет дослідження – методи прогнозування забруднення доріг, моделі нейронної мережі для визначення забрудненості та здійснення прогнозу.

Методи дослідження, використані для виконання поставлених завдань: для виявлення забрудненості – вдосконалена нейронна мережа CNN та LSTM; для прогнозування забруднення доріг – нейронна мережа LSTM, в поєднанні з CNN та повнозв'язними шарами.

Наукова новизна одержаних результатів. В результаті роботи були отримані наступні положення наукової новизни:

1. Запропоновано метод прогнозування забруднення доріг на основі підходу глибокого активного навчання. При розробці методу були застосовані глибокі нейронні мережі для підходу активного навчання, для аналізу та прогнозування забруднення доріг. Було адаптовано нейронну мережу до предметної області, а саме до розпізнавання забруднення доріг шляхом зміни гіперпараметрів, що в подальшому дозволяє прогнозувати рівень такого забруднення з зображень.

2. Вдосконалено нейромереві моделі для визначення рівня забрудненості доріг на зображенні та для прогнозування рівня забруднення. Було використано поєднання кращих особливостей декількох нейромеревих моделей – CNN, LSTM, повнозв'язних шарів, що дозволяє з високою точністю оцінити та отримати як результат рівень забрудненості дороги на зображенні у відсотках.

Апробація результатів кваліфікаційної роботи магістра та публікації. Основні наукові та практичні результати опубліковані у Збірник наукових праць за матеріалами XIV Всеукраїнської науково-практичної конференції «Актуальні проблеми комп'ютерних наук АПКН-2023». - Хмельницький, 2023. - С. 280-283 за темою роботи: Смолієнко Д. В., Петровський С.С. Метод прогнозування забруднення доріг на основі підходу глибокого активного навчання. Також, результати роботи опубліковані у науковому журналі – Метод прогнозування забруднення доріг на основі підходу глибокого активного навчання / Смолієнко Д.В., Петровський С.С // Науковий журнал «Вісник Хмельницького національного університету. Серія: Технічні науки» Хмельницький, 2023, №6 (Довідка з редакції).

Структура та обсяг роботи. Дипломна робота магістра складається з завдання, реферату, змісту, переліку скорочень, вступу, 4 розділів, висновків, переліку посилань із 40 найменувань та 2 додатків. Загальний обсяг дипломної роботи магістра становить 82 сторінки, з них 71 сторінка основного тексту та 11 сторінок додатків. У роботі наведено 22 рисунки.

Ключові слова: забруднення доріг, глибоке активне навчання, прогнозування, зображення, нейромереві, транспорт.

Розділ 1 Сучасний стан методів прогнозування забрудненості доріг методами штучного інтелекту

1.1 Аналіз сфери прогнозування забрудненості доріг

Стале та стрімке збільшення рівня забрудненості на дорогах у населених пунктах України і світу становить велику загрозу для суспільства. Швидке зростання абсолютних демографічних показників світу є причиною підвищення кількості продуктів промислового та продовольчого виробництва.

Наслідком підвищення рівня продуктів спожитку стає зростання і кількості сміття – відходів від первинного та вторинного виробництва, від сільського господарства, побутових відходів [1]. Це сприяє необхідності у постійній обробці цих викидів, що з кожним роком стає більш важчим. Так, на сьогодні, в Україні лише 5% усіх відходів утилізується, коли ж набагато більша частка потрапляє на вулиці, дороги, сміттєзвалища [2].

Крім того, зі збільшенням населення світу збільшується кількість автомобілів на дорогах, що також вплине на стан доріг [3]. Вплив автомобілів на дорожню інфраструктуру є негативним через постійне тертя шин і вихлопні гази, які вони утворюють; хімічні викиди автомобілів і фактор людських лінощів на дорогах, коли люди викидають сміття різного характеру просто з вікна транспорту.

В таких умовах інфраструктура доріг занепадається через зріст відходів на них, що впливає на життя будь-якої людини. Через підвищення рівня забруднення доріг, погіршуються мобільність населення – внаслідок сповільнення руху транспорту, здоров'я населення – через наявність на дорогах і шкідливих речовин, стан доріг – через хімічні та фізичні реакції зі сміттям.

Ці фактори вимагають постійного очищення та моніторингу доріг. У таких випадках прогнозування забруднення доріг у режимі реального часу стає дуже важливим, що дозволяє швидше обробляти дані та завчасно вирішувати проблеми без негативних наслідків.

Прогнозування дасть можливість визначити рівень забрудненості, причини цього та можливість аналізу забрудненості для певних регіонів у певні проміжки часу. Метою застосування прогнозування забрудненості є запобігання занепаданню інфраструктури, мінімізація економічних наслідків, спричинених прибиранням і руйнуванням доріг внаслідок їх забрудненості (Рисунок 1.1) [4], покращення стану екології, що також веде до зниження ризику захворювань для населення.

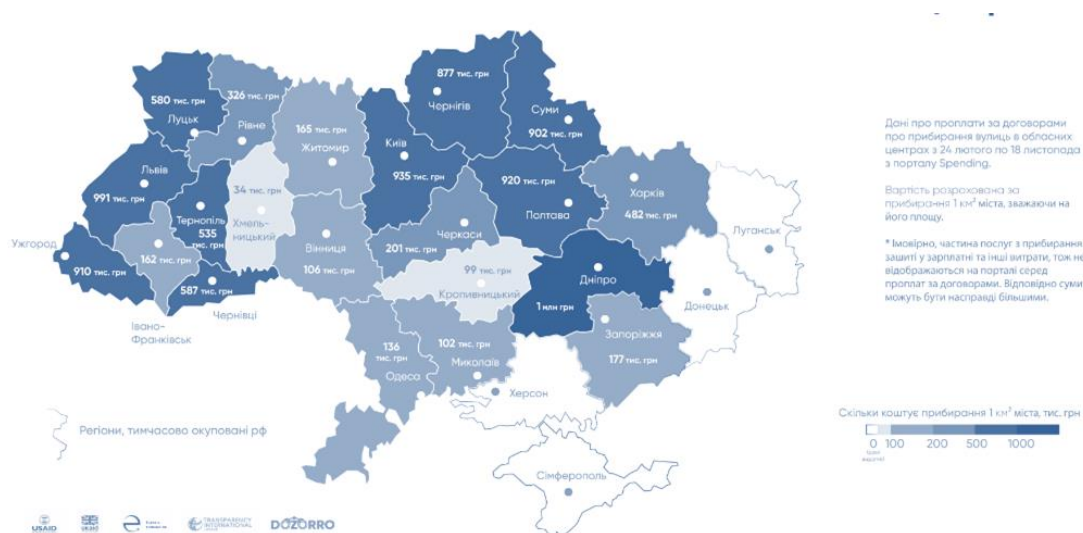


Рисунок 1.1 – Витрати на дорожню інфраструктуру в Україні [4]

Для ефективного прогнозування забруднення доріг необхідно враховувати такі основні показники:

- візуальна характеристика дорожнього покриття - наявність сміття, бруду, пошкоджень, вибоїн тощо;
- інтенсивність транспортного потоку - збільшення трафіку збільшує забруднення доріг.
- погодні умови – дощ, сніг, температура, що впливають на рівень забруднення та знос доріг.

Є кілька існуючих підходів, що використовуються для прогнозування забрудненості доріг. Один з них – без використання інформаційних технологій – людський, складається з таких основних компонентів: постійний нагляд за станом

інфраструктури доріг; моделювання ймовірності виникнення певного рівня сміття на дорогах за рахунок звітів про нагляд за ними; прогнозування майбутніх ризиків шляхом аналізу факторів, що впливають на рівень забрудненості.

Постійний нагляд за станом інфраструктури доріг в основному включає роботу комунальних підприємств, - збір даних на регулярній основі, які надають комунальні працівники, котрі працюють у певних містах та регіонах. Для більшості країн – це стала норма, яка просувається вже довгий період часу. Швидкий збір даних та їх оцінка в таких країнах сприяє квалітивому виявленню змін та проблем, які необхідно вирішити.

Прогнозування майбутніх ризиків, що включає рівень забрудненості доріг включає і моделювання, що у випадку цієї проблеми базується на статистичних даних, зібраних раніше. Такий підхід потребує вибірки з великого діапазону даних, що включає регіон, клімат, трафік, кількість населення та стан самої інфраструктури. Прогнози, що отримуються внаслідок такого підходу моделювання показують стан доріг в минулому і в майбутньому, і дозволяють частково цей стан покращити.

Такі прогнози можуть проводитися як щороку, так і щомісячно. Однак вони проводяться людьми, що витрачає значну кількість часу і фізичних зусиль, що може призвести до помилок на будь-якому з етапів.

Також існують методи прогнозування з використанням нейронних мереж і штучного інтелекту. Це автоматизовані методи глибокого навчання, що роблять прогноз за допомогою зображень.

Більшість таких методів є розробками інститутів та університетів, і користуються попитом для прогнозування у різних сферах, і лише в малих випадках - у прогнозуванні саме забрудненості доріг. [5]

Ці методи працюють на моделях глибокого навчання. Прикладами є: CNN (Convolutional Neural Networks), RNN (Recurrent Neural Networks), LSTM (Long Short-Term Memory), MLP (Multilayer Perceptron). Існуючі методи, що працюють на цих моделях показують високу якість роботи у результатах, що показують рівень прогнозування.

Існують і інші методи. Традиційні підходи аналізу даних, такі як кластеризація, регресійний аналіз, системи підтримки прийняття рішень, які дозволяють ефективно використовувати наявну інформацію для вивчення проблеми забруднення доріг та розробки стратегій управління транспортними потоками. Застосування цих методів не вимагає складного навчання моделей та значних обчислювальних ресурсів.

Водночас, технології глибокого навчання відкривають принципово нові можливості для аналізу великих масивів даних та пошуку прихованих закономірностей. На відміну від традиційних алгоритмів машинного навчання, глибокі нейромережі здатні самостійно виявляти інформативні ознаки та будувати складні моделі залежностей, що дозволяє їм досягати вищої точності прогнозування та оптимізації складних процесів.

Для ефективної роботи методу прогнозування забрудненості доріг потрібно вчасно отримувати та одразу обробляти актуальні дані про забрудненість. Частота оновлення таких даних може бути доволі високою і буде залежати виключно від регіону, з якого були зібрані дані. Тому важливим має бути не лише точність прогнозування, але й швидкодія.

Таким чином, для аналізу сфери прогнозування забрудненості доріг було проведено огляд проблеми та існуючих методів прогнозування. Результати показали, що на сьогодні є доцільним і необхідним розробка інноваційного методу прогнозування забруднення доріг на основі підходу глибокого активного навчання, позитивними сторонами якого мають стати не лише точність, але і його швидкодія.

1.2 Аналіз математичних моделей прогнозування забруднення доріг

Аналіз та математичне моделювання прогнозування забруднення дороги відіграє важливу роль у плануванні заходів щодо дій над інфраструктурою доріг. Математичні моделі можуть включати як рівняння, так і цілі системи рівнянь, параметри яких будуть представляти об'єктивні кількісні співвідношення параметрів

процесів забруднення доріг. Мета такого моделювання – визначення характеристик, динаміки та впливу забруднення доріг.

При вирішенні задачі з прогнозування забруднення дороги можна скористатися моделлю часових рядів, яка працює наступним чином:

1) збираються вхідні дані про фактичний рівень забруднення дороги за останні проміжки часу;

2) зібрані дані формуються у часовий ряд, що аналізується на наявність тренду, наявність сезонних або ж циклічних коливань;

3) на основі виявлених закономірностей будується математична модель, що описує динаміку часового ряду;

4) модель перевіряється на адекватність - співпадіння даних (параметрів/функцій/характеристик) моделі та відповідних даних модельованого об'єкта. В разі не співпадіння – модель будується повторно;

5) на основі результатів описаної динаміки модель використовується для розрахунку прогнозу забруднення дороги (такі прогнози можуть супроводжуватися оцінками їх точності);

6) за необхідності, модель може коригуватися шляхом модифікації її структури або параметрів, якщо результат виявляється незадовільним.

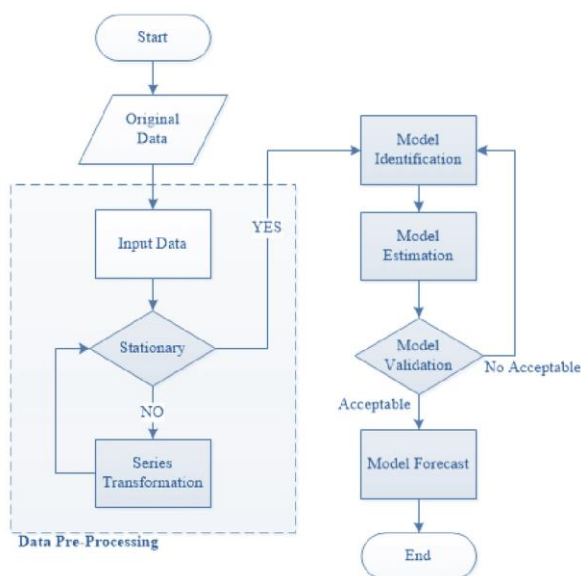


Рисунок 1.2 – Модель часових рядів [6]

Головним недоліком такої моделі є неврахування впливу різних факторів на забруднення (інтенсивність руху, погодні умови тощо). Через це при великій кількості вхідних даних може бути складно оцінити точність прогнозів забруднення дороги, що є основною проблемою.

Стохастичні моделі - це моделі, в яких параметри, умови роботи та характеристики стану модельованого об'єкта представлені випадковими величинами і пов'язані стохастичними (випадковими, нерегулярними) залежностями, або вихідна інформація також представлена випадковими величинами.

Стохастична модель прогнозування забруднення доріг враховує ймовірний характер деяких факторів. Спочатку ідентифікуються ключові змінні, що впливають на забрудненість - інтенсивність руху, швидкість вітру тощо. Для факторів, які мають випадковий характер, зібрані дані аналізуються для визначення типу ймовірнісного розподілу. На основі цього будується модель у вигляді стохастичних рівнянь, які зв'язують забрудненість з факторами через їх імовірнісні характеристики. Модель верифікується та використовується для моделювання багатьох сценаріїв реалізації випадкових факторів. Результатом є розподіл ймовірностей прогнозованого забруднення.

Але прогнози такої моделі для прогнозування забруднення доріг не є привабливими, бо мають саме ймовірнісний характер, що ускладнює процес прийняття однозначного рішення.

Таким чином, стає зрозуміло, що математичне моделювання, не дивлячись на неточність прогнозів, точно дає визначити характеристики, динаміку та вплив на рівень забруднення доріг, що може бути використане при розробці методу прогнозування забруднення доріг за підходом глибокого активного навчання.

1.3 Аналіз існуючих публікацій для прогнозування забрудненості доріг

Прогнозування забруднення доріг – проблема, що бере свою історію ще з самого початку існування дорожньої інфраструктури. Також значна кількість зусиль

була прикладена не лише для усунення проблеми фізично, але й для інтелектуального вирішення цієї проблеми.

Від простих математичних моделей до наукових публікацій з дослідження можливостей передбачення забрудненості доріг - науковці зі всього світу докладають зусиль для вирішення проблеми різними шляхами: теоретичними, математичними та за допомогою використання інформаційних технологій, зокрема за підходом глибокого активного навчання.

Глибоке активне навчання (Deep Active Learning) [7] – інноваційний підхід для вирішення задач з прогнозування. Deep Active Learning - це підхід машинного навчання, спрямований на мінімізацію кількості позначених даних, необхідних для навчання моделі. Він поєднує Deep Learning з Active Learning.

У парадигмі активного навчання, модель самостійно відбирає найбільш інформативні приклади з даних для подальшої ручної анотації експертами. Такий підхід дозволяє досягти високої точності моделі при меншій кількості анотованих даних, порівняно з традиційними підходами машинного навчання.

Відбір найбільш значущих для моделі прикладів у цьому методі базується на оцінці невизначеності, з якою модель робить прогноз для цих даних. Іншими словами, чим менш впевненими є прогнози моделі, тим ціннішою вважається інформація про реальні мітки для цих прикладів. Отримані в результаті ручної анотації дані додатково використовуються для доналаштування параметрів моделі з метою підвищення її узагальнюючої здатності.

Глибоке активне навчання використовує переваги методів глибокого навчання в поєднанні з концепціями активного навчання. У цьому підході модель спочатку попередньо тренується на обмеженій множині анотованих даних. Потім вона аналізує великі обсяги немаркованих даних та вибирає приклади, що є найбільш невизначеними та інформативними для моделі. Отримані таким чином нові анотовані дані додаються до навчальної вибірки для подальшого тренування моделі з метою покращення її узагальнюючої здатності. Такий підхід дозволяє ефективно поєднувати переваги методів глибокого навчання, зокрема здатність вилучати складні ознаки з

даних, з активним навчанням, яке дає можливість спрямовано покращувати якість навчальної вибірки.

Такий підхід може значно зменшити обсяг даних, необхідних для навчання високоточних моделей глибокого навчання. На основі підходу глибокого активного навчання вже вирішувалися проблеми, пов'язані з забрудненням міської та дорожньої інфраструктури [8].

Метод передбачення забрудненості доріг на основі глибокого активного навчання із використанням зображень доріг – вулиць населених пунктів – працює для отримання оцінки щодо забрудненості дороги з зображення[9].

У методі було застосовано стратегію глибокого активного навчання для маркування даних, яке складається з трьох частин: початкова розмітка експертами, автоматичне маркування моделлю, і подальше коригування даних експертами.

Дослідження відкрило перспективи застосування штучного інтелекту для вирішення проблеми забруднення міської інфраструктури, використовуючи оптимальну модель із досліджених експертами – YOLOv5.

Унікальністю такого методу передбачення забруднення доріг стала можливість застосування його у реальному часі, що дозволяє цілодобово слідкувати за станом інфраструктури, зміною забрудненості дороги залежно від території чи навколишніх чинників.

Не дивлячись на швидкодію та високу точність такого методу, існує потреба у великій розміченій вибірці для навчання моделі, що робиться вручну. Також модель у цьому методі навчена на обмеженому наборі класів (огорожі, вибоїни, тротуари) – самі дороги тут майже не оцінювалися. Ефективність цього методу була перевірена лише на зображеннях одного регіону, що не показує можливість застосування її для всього світу. Також детальне дослідження цього методу показує, що можуть виникнути проблеми з точністю роботи системи у складних умовах освітлення, погоди тощо.

Таким чином, підхід глибокого активного навчання є доцільним для використання у ході розробки методу, так як застосування підходу Deep Learning до

підходу Active Learning дозволить шукати ознаки на великому наборі даних, а працювати і навчатися вже на вибірці з більш точних та критичних даних.

Також стає зрозуміло, що на сьогоднішній день, існує необхідність у створенні методу саме прогнозування забруднення дороги на основі підходу глибокого активного навчання.

1.4 Аналіз нейромережевих моделей прогнозування забруднення доріг

Аналіз та моделювання забруднення доріг відіграє велику роль у плануванні заходів щодо прибирання інфраструктури, її розбудови та підтримки, що мають бути застосовані у випадку різкого зросту забруднення. Основною метою такого моделювання є визначення даних, що потрібно обробити для подальшого прогнозування. Набір таких даних може складатися з великої кількості зображень, або ж фото, що були зроблені або саморуч комунальними працівниками, або за допомогою датчиків чи камер спостереження.

Моделі глибокого навчання – це штучні нейронні мережі, які можуть вивчати та витягувати складні шаблони та властивості з великих наборів даних. Ці моделі складаються з кількох шарів, підключених вузлів або нейронів, які аналізують і змінюють вхідні дані для отримання виходу.

Моделі глибокого навчання особливо підходять для завдань, які вимагають високої точності, наприклад для розпізнавання зображень, що в свою чергу є дуже корисним для подальшого прогнозування забруднення доріг.

Вхідні дані в таких моделях надходять на вхідний рівень моделі, а дані проходять через низку прихованих шарів перед тим, як надати вихідний прогноз. Кожен прихований шар виконує серію математичних операцій над вхідними даними та надає остаточний прогноз перед передачею вхідних даних на наступний рівень.

Основним результатом такого прогнозу має бути моніторинг стану дороги у певному регіоні для оцінки її забрудненості в часі. Однією з таких моделей є CNN (Згортова нейронна мережа). [10]

CNN складається з серії згорткових, об'єднаних і повністю зв'язаних рівнів. Вхідними даними є зображення, а виходом є передбачення мітки класу зображення.

Застосовуючи спеціальні операції (фактично згортки), згорткові нейронні мережі можуть одночасно зменшувати обсяг інформації, що зберігається в інформаційній пам'яті, що дозволяє їм краще обробляти зображення з вищою роздільною здатністю. Ви можете виділити ключові характеристики зображення, такі як: край, контур або поверхню. Наступний рівень обробки дозволяє нам розпізнавати повторювані фрагменти текстури з цих країв і поверхонь і збирати їх у фрагменти зображення.

Згортковий шар CNN створює карту функцій, виконуючи скалярний добуток між вхідним зображенням і набором фільтрів. Об'єднання шарів зменшує розмір карти функцій, оскільки зменшує її дискретність.

Мітки класів зображень прогнозуються за допомогою карти функцій повністю підключеного шару (Рисунок 1.3).

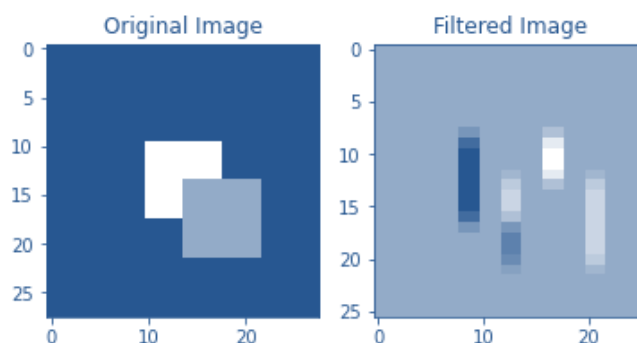


Рисунок 1.3 – Згортковий шар з оригінальним і обробленим зображенням

Згорткові нейронні мережі не є інваріантними до системи координат. Це означає, що коли вхідне зображення повертається або переміщується, вихід мережі змінюється. Це може бути проблемою в деяких програмах, де важлива орієнтація або положення об'єкта.

Серед сучасних методів машинного навчання **RNN** [11] (рекурентні нейронні мережі) представляють особливий інтерес для аналізу часової динаміки складних процесів.

Зворотний зв'язок і пам'ять дозволяють враховувати контекст і історичні дані під час аналізу поточного стану процесу (Рисунок 1.4). Це робить RNN ефективним інструментом для моделювання та прогнозування часових рядів.




Рисунок 1.4 – Врахування зворотнього зв'язку для аналізу поточного стану процесу в моделі RNN

Моделі RNN можуть точно прогнозувати майбутні значення, беручи до уваги вплив минулих подій і умов, трендів і сезонних коливань.

Однак у RNN є деякі проблеми. RNN страждають від проблем із зникаючим градієнтом і вибуховим градієнтом. [12]

Мережі довгої короткочасної пам'яті (**LSTM**) [13] можна розглядати як розширення RNN, і тут також застосовується концепція збереження контексту вхідних даних.

Однак LSTM було змінено кількома важливими способами, щоб забезпечити кращу інтерпретацію попередніх даних. Зміни, внесені до LSTM, вирішують проблему зникаючого градієнта та дозволяють LSTM вміщувати набагато довші вхідні послідовності.

Модель LSTM складається з трьох різних компонентів або воріт. Є вхідні ворота, вихідні ворота та ворота забуття (Рисунок 1.5). Подібно до RNN, LSTM враховують вхідні дані з попередніх часових кроків під час зміни пам'яті та ваг моделі.

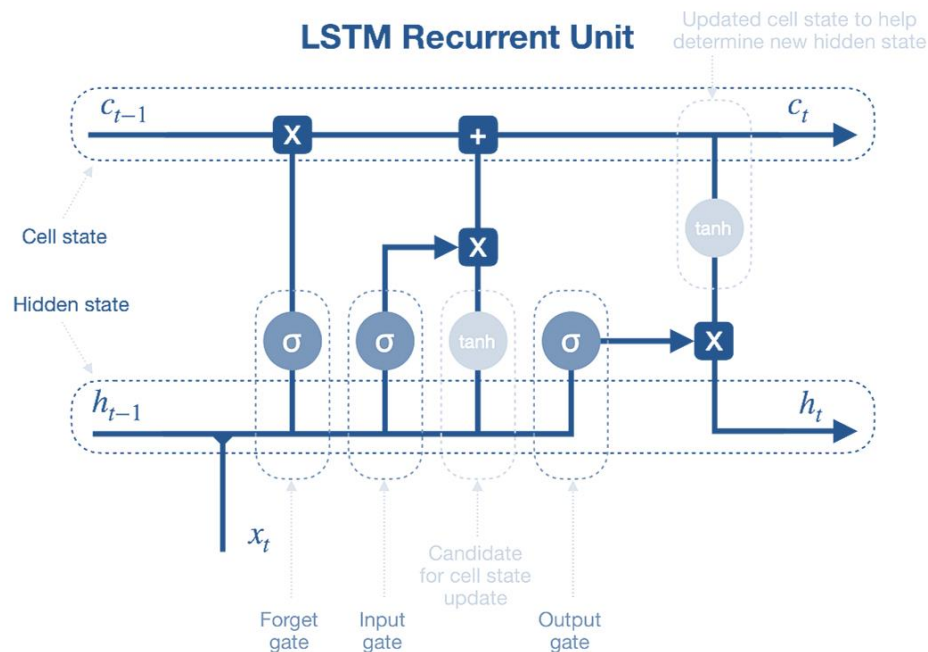


Рисунок 1.5 – Компоненти моделі LSTM [13]

Вхідні ворота визначають, які значення є важливими та потрібно передати в модель. Вхідний шлюз використовує сигмоїдну функцію, щоб визначити, які значення передаються через рекурентну мережу.

Після розгляду поточних вхідних даних і стану пам'яті вихідний клапан вирішує, яке значення перенести на наступний часовий крок. У вихідній схемі значення аналізуються та призначаються значення. Ці значення відкоригують дані перед передачею до наступного обчислення.

Нарешті, завдання шлюзу забуття полягає у видаленні інформації, яку модель вважає непотрібною для визначення типу вхідного значення. Ворота забуття використовують сигмоїдну функцію для значення та виводять одне зі значень – «забуто» чи «збережено».

Щоправда, набагато довші вхідні послідовності вимагають більшої кількості обчислень. Це відкриває великий недолік моделі LSTM - збільшення витрат на обчислювальні ресурси.

Метод MLP (метод багатошарового перцептронну) [14] є доповненням до прямої нейронної мережі. Як показано на малюнку (Рис. 8), він складається з трьох типів шарів: вхідного, вихідного та проміжного.

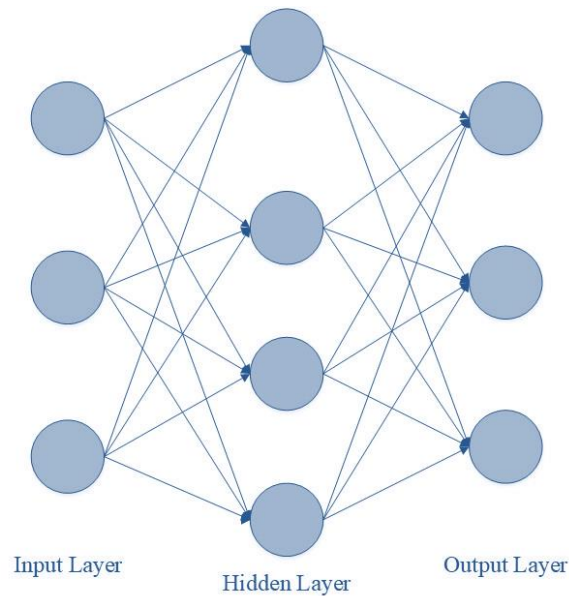


Рисунок 1.6 – Метод багатошарового перцептронну [13]

Вхідний рівень отримує вхідний сигнал для обробки.

Такі необхідні завдання, як прогнозування та класифікація, виконуються вихідним рівнем. Будь-яка кількість прихованих шарів, розміщених між вхідним і вихідним шарами, є фактичним обчислювальним механізмом MLP.

Подібно до прямої нейронної мережі, в MLP дані проходять вперед від вхідного рівня до вихідного рівня. Нейрони в MLP навчаються за допомогою алгоритму навчання зворотного поширення.

MLP спрямований на апроксимацію довільних неперервних функцій і вирішення проблем, які не є лінійно роздільними. Основним використанням MLP є класифікація зображень, розпізнавання, прогнозування та наближення.

Багатошарові перцептрони з прихованими шарами мають неопуклу функцію втрат, коли існує більше одного локального мінімуму. Тому різні ініціалізація випадкових ваг може привести до різної точності моделі, що є великим недоліком цієї моделі.

Отже, було проаналізовано нейромережеві моделі, які можуть бути використані для прогнозування забруднення доріг за допомогою зображень. Було знайдено, як і переваги, так і недоліки кожного методу. Їх загальна оцінка показує доцільність створення вдосконаленої моделі, що буде працювати за схожими параметрами, але буде враховувати усі недоліки досліджених моделей.

1.5 Постановка задачі

Мета кваліфікаційної роботи магістра - створення методу прогнозування забруднення дороги на основі підходу глибокого активного навчання, що дозволить вирішити проблему забруднення на дорогах шляхом отримання попереднього прогнозу щодо зміни рівня забруднення цієї дороги у майбутньому .

Вхідними даними при вирішенні задачі прогнозування забруднення дороги стане вибірка із даних, що є зображеннями доріг, а вихідними даними – результати прогнозування забруднення й числові оцінки для кожного результату.

Для досягнення поставленої мети необхідно реалізувати наступні *задачі дослідження*:

1) провести аналіз предметної області, математичних моделей, нейромережевих моделей, що можуть бути використані для прогнозування забруднення доріг.

2) розробити метод прогнозування забрудненості доріг на основі підходу глибокого активного навчання.

3) вдосконалити нейромережеву модель визначення рівня забрудненості доріг.

4) навчити нейронну мережу здійснювати прогноз забруднення дороги із ряду зображень.

5) провести дослідження ефективності методу прогнозування забруднення доріг з підходом глибокого активного навчання, визначити точність роботи такого методу.

Висновки до Розділу 1

В розділі проведено аналіз проблем прогнозування забруднення доріг різноманітними методами, серед яких є методи штучного інтелекту, зокрема для аналізу визначення сучасного стану проблеми. Було проведено огляд сфери прогнозування забруднення доріг, який виявив, що на сьогодні існує необхідність в розробці нового методу для вирішення цієї задачі.

Аналіз існуючих публікацій для прогнозування забруднення доріг дозволив встановити, що на сьогоднішній день існують лише системи для класифікації зображень на наявність забрудненості доріг, встановлення типу забруднення, визначення рівня забрудненості на дорожній інфраструктурі з зображення.

Встановлено, що для прогнозування забруднення доріг варто розробити власну нейромережеву модель, враховуючи усі недоліки та проблеми, з якими можна стикнутися при роботі з дослідженими моделями. Відповідно, за вхідними даними, що є зображеннями доріг з регіонів, необхідно швидше і більш точно отримати результати, що містять результат прогнозу забруднення дороги, а також оцінку до цього результату.

В результаті, в першому розділі було визначено ціль кваліфікаційної роботи магістра як вирішення задачі прогнозування забруднення доріг на підході глибокого активного навчання. Для цього слід розробити нейромережеву модель, що буде показувати як результат прогнозування, так і його числову оцінку.

Розділ 2 Методи для прогнозування забрудненості доріг на основі підходу глибокого активного навчання

2.1 Нейромережева модель для прогнозування забруднення доріг на основі підходу глибокого активного навчання

Метод прогнозування забруднення доріг на основі підходу глибокого активного навчання призначений для отримання вихідних даних у вигляді результату, що містить прогнозовані варіанти рівня забруднення і оцінки кожного з них. Вихідні результати отримуються протягом досліджуваного періоду за вхідними даними вибірок актуальних даних.

Метод відрізняється від існуючих тим, що здатен високоякісно прогнозувати наперед, що дозволить вжити заходів щодо роботи з дорогами ще до того, як вона зможе забруднитись.

Для розробки методу запропоновано використання комбінованої моделі, що дозволить враховувати як локальні закономірності за допомогою 1D згорток – частина архітектури Convolutional Neural Network, так і довготривалі тенденції, що було отримано за допомогою LSTM-рекурентного шару. Така гібридна архітектура надає моделі як просторові, так і часові можливості для аналізу даних та їх прогнозування.

Схема етапів такої моделі навчання для методу прогнозування забруднення доріг на основі підходу глибокого активного навчання зображена на рисунку 2.1.

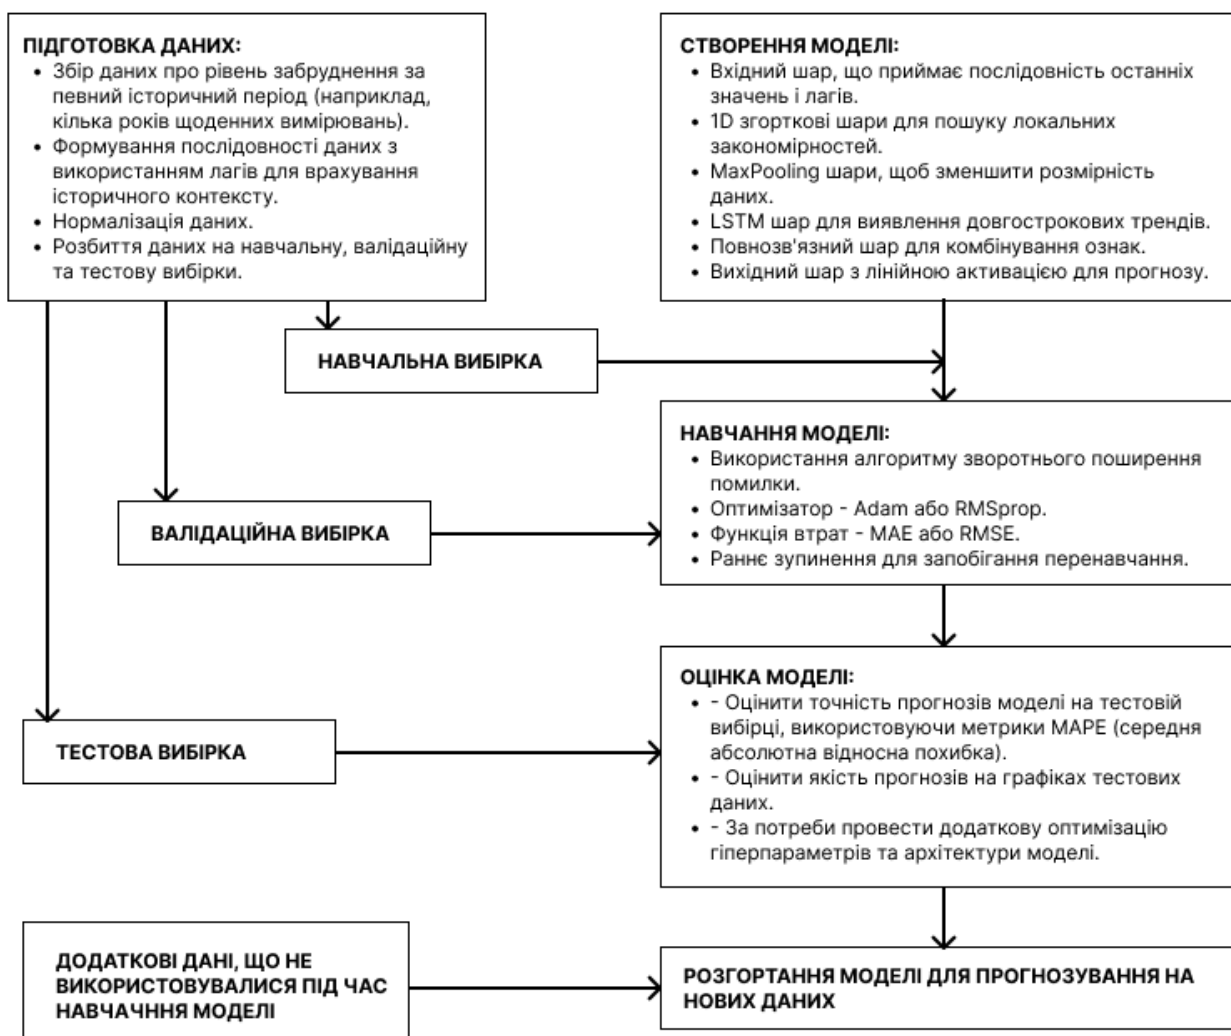


Рисунок 2.1 – Схема етапів моделі навчання

На першому етапі відбувається підготовка даних для створення ефективної моделі прогнозування забруднення доріг. Тут необхідно спочатку зібрати актуальні дані стану доріг та підготувати історичні дані цієї ж місцевості, які будуть використовуватися для навчання моделі. Спочатку, згідно до описаного підходу до збільшення розмірності вхідних даних, потрібно отримати часовий ряд вимірювань рівня забруднення за певний період – для методу на основі підходу глибокого активного навчання, такий певний період має бути якомога триваліший – наприклад кілька років щоденних даних.

Далі на основі цих даних формується вхідна послідовність з використанням лагів, а тобто з додаванням зміщених у часі даних для врахування історичного

контексту. Також важливим кроком стане нормалізація даних, що приведе, що дозволить привести їх до одного діапазону. Після цього вхідна послідовність даних розділяється на три вибірки: навчальну, валідаційну та тестову.

Навчальна вибірка використовуватиметься для подальшого тренування моделей, що покажуть тестові результати, на основі яких буде використана валідаційна вибірка – для налаштування гіперпараметрів. Третя вибірка – тестова – слугує для остаточної оцінки якості роботи моделі.

Така ретельна підготовка даних є запорукою того, що модель зможе навчитися знаходити приховані закономірності та точно прогнозувати майбутні значення часового ряду.

На другому етапі відбувається створення моделі методу прогнозування забруднення доріг на основі підходу глибокого активного навчання. На цьому етапі необхідно визначити архітектуру нейронної мережі, що включатиме такі основні компоненти:

- вхідний шар, що буде приймати підготовлену послідовність даних у вигляді часового ряду з лагами.

- 1D згорткові шари, які автоматично зможуть виділяти інформативні ознаки вхідних даних, вловлюючи локальні закономірності в них.

- MaxPooling шари, використання яких зменшує розмірність вхідних даних має кілька переваг: зменшення обчислювальної складності моделі за допомогою зменшення параметрів моделі, що пришвидшує навчання; регуляризація моделі за допомогою запобігання перенавчанню; виділення найбільших ознак за допомогою вибору максимальних значень з кожної області і фільтрування менш інформативних даних; надання моделі інваріантності до невеликих зсувів у даних. Це корисно для роботи з часовими рядами.

- LSTM шар моделі аналізуватиме отримані ознаки в послідовності, моделюючи довгострокові залежності.

- повнозв'язний шар для комбінування ознак перед фінальним прогнозом.

- вихідний шар з лінійною активацією reLU, що видає прогнозоване значення рівня забруднення через певний час.

На третьому етапі відбувається саме навчання моделі прогнозування забруднення доріг на основі підходу глибокого активного навчання. Навчання моделі можна зробити наступним чином.

Нехай x - вхідні зображення доріг за попередні часові проміжки, y - цільовий рівень забрудненості на вказаний часовий проміжок (якщо у вибірці зображення були зроблені протягом кожного дня в період одного тижня, то вказаний часовий проміжок – наступний день). Тоді модель глибокого навчання можна представити як функцію f , що намагається наблизити y :

$$y = f(x; \theta),$$

де θ - параметри моделі, які підлаштовуються в процесі навчання.

Використовуючи алгоритм зворотнього поширення помилки можна отримати оновлення ваг моделі на основі градієнта функції втрат.

Після цього за обраним оптимізатором Adam, який поєднує переваги одразу декількох існуючих методів, адаптивно налаштувати швидкість навчання для кожного параметра, що прискорює конвергенцію.

Оптимізація θ проводиться за допомогою градієнтного спуску та оновлення параметрів:

$$\theta' = \theta - \alpha \nabla_{\theta} L(\theta),$$

де α - швидкість навчання.

Саме навчання в основному полягає у функції втрат $L(\theta)$ середньоквадратичної похибки:

$$L(\theta) = 1/N \sum (y - f(x; \theta))^2,$$

де N - розмір набору даних.

Для функції втрат на цьому етапі слід використати середньоквадратичну помилку RMSE, яка є доцільною через свою чутливість до великих похибок і підходить для задач регресії та прогнозування.

Після цього застосовується метод ранньої зупинки, щоб припинити навчання, коли помилка на валідаційній вибірці перестане зменшуватись. Це дозволить уникнути перенавчання, а отже і пришвидшить роботу методу.

На останньому етапі відбувається підбір гіперпараметрів (швидкість навчання, розмір міні-батчів, кількість епох) за допомогою валідаційної вибірки.

Після навчання моделі – на четвертому фінальному етапі – відбувається оцінка її якості за допомогою використання тестової вибірки. На цьому етапі роботи моделі прогнозування забруднення доріг на основі підходу глибокого активного навчання необхідно оцінити її якість:

- оцінити точність прогнозів моделі на тестовій вибірці, використовуючи метрики MAPE (середня абсолютна відносна похибка).

- оцінити якість прогнозів на графіках тестових даних.

- за потреби провести додаткову оптимізацію гіперпараметрів та архітектури моделі.

Після побудови та оцінки ефективності моделі прогнозування забруднення доріг на основі історичних даних, наступним логічним кроком є її розгортання в системі моніторингу в режимі реального часу.

Для цього розроблена модель інтегрується в загальну систему збору та обробки даних про поточний стан дорожнього покриття. Сенсори в реальному часі збирають нові дані, які проходять попередню обробку - очищення, нормалізацію, формування послідовності з лагами (використання попередніх значень).

Підготовлений вхідний вектор даних подається на розгорнуту модель, яка на його основі генерує прогноз майбутнього рівня забруднення.

Такий прогноз може використовуватися для вироблення рішень щодо запобігання надмірного забруднення, оптимізації роботи очисних систем, попередження населення. З часом, при надходженні все більшої кількості даних, навчання моделі може покращити її адаптацію до нових тенденцій.

Інтеграція розробленої моделі прогнозування забруднення доріг в загальну систему моніторингу та підтримки прийняття рішень дозволить використовувати генеровані нею прогнози на практиці для вирішення прикладних завдань.

Запропонована архітектура моделі є універсальною та дозволяє ефективно справлятися із часовими рядами даних, представленими як у вигляді зображень стану дорожнього покриття, так і будь-якими іншими даними щодо рівня забруднення. Незалежно від поточного стану, модель здатна спрогнозувати динаміку зміни рівня забрудненості у певні майбутні моменти часу.

Такий підхід дозволяє представляти результати прогнозування у зручному вигляді у відсотках забрудненості дороги, що спрощує їх подальше використання для планування робіт з прибирання та інших задач у сфері управління станом дорожньої інфраструктури.

2.2 Підхід до збільшення розмірності вхідних даних для прогнозування забрудненості доріг на основі підходу глибокого активного навчання

Для підвищення ефективності розробленого методу прогнозування забруднення доріг на основі глибокого навчання було застосовано підхід збільшення розмірності вхідних даних за рахунок додавання лагів (lags) [15].

Лаги дозволяють врахувати попередню історію спостережень часового ряду шляхом включення до вхідних даних моделі значень зі зсувом у часі. Кожен лаг має порядок k , що визначає величину зсуву даних у минуле відносно поточного кроку прогнозування.

Застосування лагів надає можливість моделювати історичні закономірності та тенденції динаміки зміни рівня забруднення доріг. А врахування попередніх значень часового ряду, в свою чергу, підвищує точність прогнозованої моделі для коректного моделювання майбутньої поведінки процесу, що аналізується.

До прикладу, існує часовий ряд даних про рівень забруднення дороги за останні 7 днів. Позначимо f_i фактичне значення рівня забруднення в день i . Тоді при

заданому порядку лагу $k=1$ буде сформовано додаткову ознаку $f(i-1)$, що відповідає значенню попереднього дня. Приклад таких даних показано у таблиці 2.1

Таблиця 2.1 – дані про забруднення дороги за останні 7 днів

День	Значення	Послідовність лагів
День 1	0.5	NaN (значення відсутнє)
День 2	0.7	0.5
День 3	0.4	0.7
День 4	0.6	0.4
День 5	0.8	0.6
День 6	0.3	0.8
День 7	0.9	0.3

Основною метою застосування підходу збільшення розмірності вхідних даних за допомогою лагів є можливість моделі краще виявляти різноманітні тимчасові закономірності часового ряду.

Зокрема, наявність попередньої історії у вхідних даних дозволяє моделі прогнозування ефективніше визначати сезонні, циклічні та інші тренди. Наприклад, виявляти певні закономірності щотижневих коливань рівня забруднення доріг, що можуть бути пов'язані з особливостями руху транспорту та погодними умовами у різні дні тижня.

Завдяки наявності даних зі зсувом у часі (лагів попередніх значень) з'являється можливість пов'язати поточні спостереження з минулими (Рисунок 2.2). Наприклад, при моделюванні з використанням зображень, значення рівня забрудненості на поточному знімку залежить від стану на попередніх зображеннях з урахуванням інерційності процесів забруднення.

Такий підхід дає змогу точніше моделювати динаміку змін та прогнозувати майбутні значення рівня забрудненості на основі аналізу поточного стану з урахуванням попередньої історії часового ряду.



Рисунок 2.2 – Поєднання поточних значень із лагами

Модель, що використовує лаги також може визначати тренди та довгострокові тенденції в даних (залежність від погодних умов, сезонні коливання, добові коливання трафіку).

Найкращою перевагою збільшення розмірності даних за допомогою лагів є збільшення кількості даних для навчання моделі, що покращить її узагальнюючу здатність прогнозування.

Крім того, для прогнозування забрудненості доріг на підході глибокого активного навчання слід використати згорткові шари – шари, отримані в результаті процесу згортки сигналів виходів попереднього шару.

Згорткові шари дозволяють автоматично вилучати найпотрібніші ознаки з послідовності вхідних даних – зображень з забрудненням доріг, - але в тому числі ще і з лагів. Це суттєво зменшує необхідність в ручній інженерії ознак, і водночас додатково збільшує кількість даних, що робить метод прогнозування забруднення доріг більш привабливим і легким у використанні.

Комбінація лагів та згорток надає моделі як глобальний контекст (за рахунок роботи лагів), так і можливість вилучати локальні ознаки, тобто згортки. Поєднання цих підходів допоможе побудувати більш гнучку та потужну модель для такої складної задачі, як прогнозування забрудненості доріг у часі, додатково враховуючи різні можливі аспекти даних.

При використанні згорткових шарів у поєднанні з лагами доцільно використати 1D згортки [16] – різновид згорткових нейронних мереж, який застосовується до даних, що мають лише один просторовий вимір.

На відміну від звичайного та більш популярного 2D згортку (для двох просторових вимірів) для зображень, в 1D згортці фільтр/ядро згортки застосовується тільки в одному напрямку – вздовж послідовності даних, а у випадку поставленої задачі – вздовж часового ряду.

Наприклад для часового ряду $[x_1, x_2, x_3, \dots, x_N]$ 1D згортка використовує фільтр $[w_1, w_2, w_3]$ та проходить фільтром вздовж послідовності, обчислюючи скалярний добуток фільтра і вікна даних.

Використання саме 1D згортки дає наступні переваги: здатність вилучати локальні шаблони з послідовностей, зменшення кількості параметрів в порівнянні з повнозв'язними шарами, нейрони окремих карт ознак будуть спеціалізуватися на певних шаблонах в даних.

Комбінування лагів і згорткових шарів буде відбуватися наступним чином (Рисунок 2.3):

1) формування двох окремих векторів:

a) вектор лагів $[z_1, z_2, z_3, z_4, z_5, \dots, z_N]$

b) вектор поточних даних $[x_1, x_2, \dots, x_N]$

2) застосування окремих 1D згортки до кожного вектора для отримання вектору ознак з лагів та вектору ознак з поточних даних.

3) конкатенація (об'єднання) векторів у вигляді: [вектор_лагів, вектор_поточних_даних]

4) подання конкатенованого вектору на вхід до шару прогнозування.

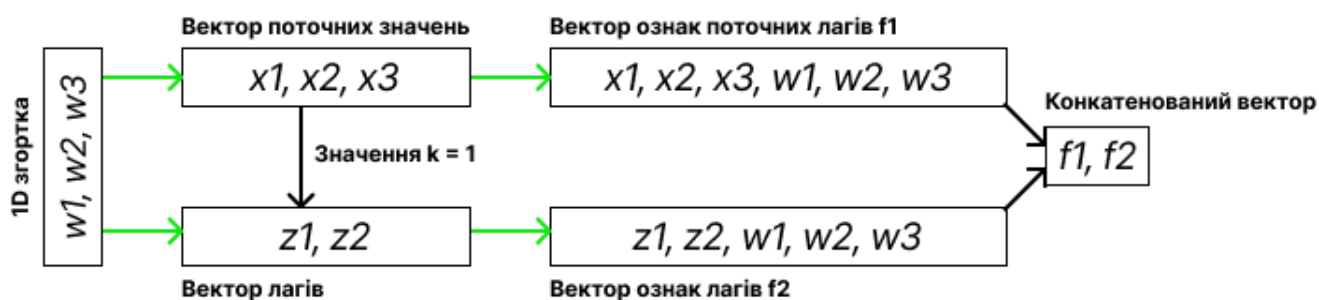


Рисунок 2.3 – Комбінування лагів і згорткових шарів для збільшення розмірності вхідних даних

Таким чином, комбінація показує користь такого методу прогнозування забруднення доріг на підході глибокого активного навчання, так як робиться вибірка найінформативніших даних, як для активного навчання, після чого виконується збільшення розмірності цієї вибірки за рахунок вектору лагів та швидкодіючої на часовому просторі 1D згортки, в результаті чого отримуємо прийнятну для глибокого навчання вибірку.

2.3 Підхід до визначення рівня забруднення доріг на основі підходу глибокого активного навчання

Для визначення рівня забруднення дороги у відсотках на основі прогнозних даних можна використати наступний підхід: Визначити мінімальне і максимальне можливі значення рівня забруднення на основі історичних даних. Нехай це $min_pollution$ і $max_pollution$ відповідно.

Нормалізувати прогнозоване значення забруднення X на шкалу $[0, 1]$:

$$X_{norm} = (X - min_pollution) / (max_pollution - min_pollution)$$

Перевести нормалізоване значення X_{norm} у відсотки:

$$X_{percentage} = X_{norm} * 100\%$$

Розділити можливий діапазон відсотків $[0\%, 100\%]$ на класи забрудненості:

- 0-20% - низький рівень
- 20-40% - помірний рівень

- 40-60% - високий рівень
- 60-80% - дуже високий рівень
- 80-100% - екстремальний рівень

Щоб визначати рівень забруднення дороги в відсотках на основі глибокого навчання, можна використати наступну нейромережеву модель, зображену на рисунку 2.4:

- завантаження даних з папок у вигляді зображень, що дозволяє зручно отримувати дані одразу для різних вибірок - навчання, валідації та тестування.
- перетворення зображень в вектори. Кожне зображення розгортається в одновимірний вектор пікселів.
- використання 1D згорткової нейронної мережі (CNN) для перетворення векторів в набір ознак. Це дозволяє витягнути інформативні ознаки з вхідних даних.
- додавання рекурентного LSTM шару для роботи з послідовностями даних. Це важливо для майбутнього дослідження часових залежностей.
- використання повнозв'язного шару на виході для отримання результату - рівня забрудненості.
- навчання моделі на підготовлених даних, оцінка на тестовій вибірці.



Рисунок 2.4 – Схема кроків нейромережевої моделі для визначення рівня забруднення

Для виконання якісної інтерпретації та автоматичного розподілу числових прогнозних значень рівня забруднення за класами забрудненості розроблено спеціальний функціональний модуль на основі технологій глибокого навчання. Застосований підхід навчання дає можливість автоматично відносити конкретні прогнозовані числові значення до одного з класів забрудненості (низький, посірний, високий, дуже високий, екстремальний) з урахуванням внутрішніх статистичних залежностей даних. Крім цього, даний функціональний модуль трансформує числові прогнози у більш зрозумілі для кінцевого користувача відносні відсоткові показники

рівня забрудненості. Такий комплексний підхід поєднує переваги глибокого навчання та забезпечення інтерпретованості результатів прогнозування.

Таким чином, було вдосконалено підхід до визначення рівня забруднення доріг шляхом поєднання найкращих рис нейромережевих моделей LSTM та CNN.

2.4 Метод прогнозування забруднення доріг на основі глибокого активного навчання

Метод прогнозування забруднення доріг на основі глибокого активного навчання з використанням зображень та часових ліній дозволяє одержувати результати за вхідними даними у вигляді вибірки залежних від часу параметрів для подальшого прогнозування.

На рисунку 2.5 зображено схему кроків реалізації такого методу прогнозування забруднення доріг на основі підходу глибокого активного навчання.

Крок 1 - Формування вектора поточних даних часового ряду показника рівня забрудненості та вектора його лагових змінних за попередні періоди. Здійснення необхідного фільтрування отриманих даних та їх конкатенація в єдиний вхідний вектор.

Крок 2 – Проведення процедури нормалізації вагових коефіцієнтів згорткового шару нейромережевої моделі з метою покращення стійкості та якості навчання.

Крок 3 – Безпосереднє навчання розробленої нейромережевої архітектури на підготовлених даних з використанням методів глибокого навчання для вирішення завдання прогнозування рівня забрудненості дорожнього покриття.

Крок 4 – Отримання результату у вигляді відсоткового значення забруднення дороги на часовому ряді – у минулому та у майбутньому.

Крок 5 – Навчання моделі до прогнозування забруднення на дорогах на основі підходу глибокого активного навчання для одержання результатів у вигляді прогнозованого рівня забруднення у майбутньому.

Крок 6 – Перевірка якості отриманих валідаційних результатів за допомогою функцій. При незадовільних результатах, де справжнє значення сильно різниться з реальним є можливість зміни гіперпараметрів моделі.

Крок 7 – Оцінка якості роботи методу на тестовій вибірці. Перевірка можливостей методу прогнозування забруднення доріг.



Рисунок 2.5 – Схема кроків реалізації методу прогнозування забруднення доріг на основі підходу глибокого активного навчання

Таким чином, вхідні дані методу прогнозування забруднення доріг на основі підходу глибокого активного навчання з використанням зображень включають вибірку із залежних від часу значень визначеного параметру (забрудненість доріг) протягом певного досліджуваного періоду. Такі вхідні дані розділені на 3 вибірки – тренувальну, валідаційну та тестову. Далі згідно підходу до збільшення розмірності даних відбувається створення вектору поточних даних та вектору лагів цих даних, далі – їх фільтрування 1D згорткою та конкатенування для створення часового ряду. Після цього відбувається нормалізація вагів згорткового шару.

Однією з ключових складових для вирішення загальної задачі прогнозування забруднення доріг є можливість кількісного вимірювання поточного рівня забрудненості. Адже для того, щоб спрогнозувати майбутній стан, необхідно мати вихідні дані про поточну ситуацію.

Саме тому в рамках дослідження було розроблено та навчено нейромережеву модель для визначення відносного рівня забрудненості дорожнього покриття на основі його зображень. Модель аналізує зображення, виділяє ознаки, що вказують на наявність бруду, і на основі них приймає рішення щодо поточного рівня забруднення.

Результати роботи моделі можуть бути представлені у зручному вигляді – у відсотках відносної забрудненості покриття. Це значення в подальшому використовується вже безпосередньо для прогнозування змін рівня забрудненості з часом.

Після побудови моделі для визначення поточного рівня забруднення, наступним кроком є розробка та навчання нейромережевої моделі безпосередньо для прогнозування змін забрудненості на основі технології глибокого навчання.

По завершенню навчання обчислюються кількісні метрики, що оцінюють точність та якість роботи моделі на тестових даних. Якщо отримані показники ефективності є незадовільними, доцільно оптимізувати процес навчання шляхом налаштування гіперпараметрів моделі та алгоритму навчання.

Кінцевим результатом запропонованого методу є можливість отримання точних значень прогнозованого рівня забрудненості дорожнього покриття на заданий

момент часу в майбутньому. Це дозволяє приймати обґрунтовані рішення щодо планування робіт з очищення та інших заходів.

Висновки до розділу 2

У даному розділі було запропоновано та вперше розроблено авторський метод прогнозування забруднення доріг на основі технології глибокого активного навчання.

Розроблений метод прогнозування забруднення доріг відрізняється від існуючих підходів, що здебільшого зосереджені на класифікації поточного стану в режимі реального часу. На відміну від них, запропонований метод дозволяє моделювати майбутню поведінку та зміну рівня забрудненості дорожньої інфраструктури на основі поточних та історичних даних.

Основою методу є застосування глибокого активного навчання шляхом побудови рекурентної нейронної мережі LSTM, що продемонструвала найкращі результати у моделюванні динамічних процесів порівняно з іншими підходами. Також було застосовано техніку збільшення розмірності даних для ефективного врахування історичних залежностей у часовому ряді.

Додатково вдосконалено процедуру визначення поточного рівня забрудненості на основі ансамблю нейронних мереж глибокого навчання CNN та LSTM для аналізу зображень та врахування історичних залежностей відповідно.

Запропонований підхід дозволяє з високою точністю прогнозувати забруднення доріг та може застосовуватись на практиці для вирішення задач планування робіт з очищення та інших цілей у сфері управління дорожньою інфраструктурою.

Розділ 3 Інформаційна система розробленого методу прогнозування забруднення доріг на основі підходу глибокого активного навчання

3.1 Модулі інформаційної системи прогнозування забруднення доріг

Для створення інформаційної системи програмного забезпечення розробленого методу прогнозування забруднення доріг на основі підходу глибокого активного навчання необхідно поділити метод на модулі (окремі компоненти програмного забезпечення) задля можливості спрощення програмної реалізації.

Архітектура інформаційної системи зображена на рисунку 3.1



Рисунок 3.1 – Архітектура інформаційної системи

Модуль «збільшення розмірності вхідних даних» для реалізації підходу до збільшення розмірності вхідних даних на основі підходу глибокого активного навчання.

Основні етапи такої структури зображені на рисунку 3.2



Рисунок 3.2 – Основні етапи структури модуля збільшення розмірності вхідних даних

На першому кроці відбувається підготовка датасету – його розбиття на 3 вибірки, що необхідні для навчання моделі, валідації результатів та тестування розробленої моделі. Саме такий датасет буде «вхідними даними», якими керуватиметься увесь метод прогнозування забруднення доріг на основі глибокого

активного навчання. Правильно розбитий на 3 теки датасет з групами зображень однієї дороги в різний період часу – дуже важливий крок підготовки даних.

Вхідні дані на другому кроці завантажуються до системи у вигляді архіву. Така дія доцільна за наступних причин.

1. Зручність. Збереження великого обсягу даних в одному архіві зазвичай зручніше, ніж у багатьох окремих файлах. Так спрощується сам процес завантаження та розподіл даних.

2. Ефективність. Завантаження одного архіву швидше та ефективніше з точки зору використання ресурсів, ніж багатьох окремих файлів для подальшого їх розподілу у три окремих теки.

3. Цілісність даних. Тримати дані для трьох різних цілей – навчання, валідації та тестування – разом в одному архіві допомагає зберегти синхронність та узгодженість їх розсташування.

4. Легше управління варіантами. Контролювати зміни варіантів багатьох окремих файлів значно складніше, ніж одного файлу-архіву.

5. Спільне використання та передача. Якщо у проекті залучені інші учасники, то такий архів легше пересилати за окремі файли. Завантаження архіву до хмарного середовища простіше і швидше.

На третьому кроці відбувається зчитування завантаженого файлу-архіву, розподіл вмісту архіву на окремі вибірки (тренувальну, валідаційну, тестувальну). В результаті лишаються першопочаткові вхідні дані, що були завантажені з більшою швидкістю та меншим використанням ресурсів.

Четвертий крок – один із основних процесів усього підходу до збільшення розмірності вхідних даних. На цьому етапі відбувається перетворення кожної вибірки у три різних вектори. Після цього за допомогою часових лагів утворюється три додаткових вектори відповідно до кожної вибірки.

На п'ятому кроці, за допомогою отриманих на четвертому кроці вхідних даних, 1D згортковим шаром відбувається прохід крізь кожен з шести утворених

векторів, для утворення векторів ознак і для поточних даних, і для часових лагів. Це дозволяє збільшити їх розмірність.

Останнім кроком цього етапу є конкатенація відповідних одне до одного векторів ознак у один, внаслідок чого кількість векторів знов повертається до трьох одиниць, але вже у декілька разів більшими.

Кожен з трьох утворених векторів можна уявити у вигляді часового ряду, який є вихідним результатом підходу до збільшення розмірності даних і який буде передано до наступного модулю.

Модуль «визначення рівня забрудненості дороги на зображенні» для реалізації нейромережевої моделі визначення рівня забрудненості дороги на зображенні на основі підходу глибокого активного навчання призначений для прийому вхідних даних у вигляді раніше утвореного часового вектору, і виводу в результаті роботи вихідних даних у вигляді рівня забрудненості дороги на дорозі у певний часовий момент.

Структура модулю нейромережевої моделі для визначення рівня забруднення дороги у відсотках на основі прогнозних даних зображена на рисунку 3.3

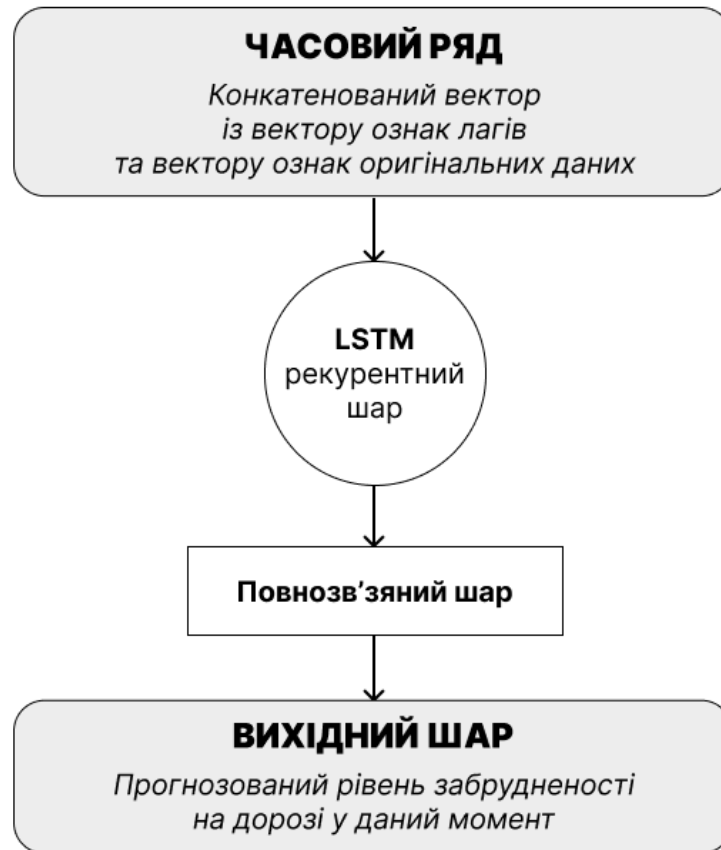


Рисунок 3.3 – Структура модуля нейромережевої моделі для визначення рівня забруднення дороги на зображенні

На першому кроці модуль отримує вхідні дані у вигляді конкатенованого часового ряду, створеного на минулому етапі збільшення розмірності даних. У цьому конкатенованому векторі зберігаються зображення, створені у різний період забрудненості дороги – наприклад, щотижневі фото впродовж року.

Ці дані на другому кроці подаються на вхід до LSTM-рекурентного шару, що здатний запам'ятовувати залежності в даних. На основі аналізу послідовності даних часового ряду, LSTM шар виявляє закономірності на основі зображень і назв навчальних і валідаційних файлів, де вказано відсотковий рівень забрудненості, та видає як результат вектор ознак.

На третьому етапі LSTM подає вектор до повнозв'язного нейронного шару. Аналізуючи і досліджуючи вектор ознак, повнозв'язний шар видає результат у вигляді рівня забрудненості дороги на даний момент (для кожного з зображень).

Результат виконання модуля є навчена модель для використання і керування отриманими результатами у вигляді рівня забрудненості доріг, що буде використано для модуля «прогнозування рівня забрудненості доріг».

Модуль «прогнозування рівня забрудненості дороги» для реалізації на основі методу прогнозування рівня забрудненості дороги на основі підходу глибокого активного навчання потрібний для реалізації головної задачі кваліфікаційної роботи магістра – прогнозування забруднення дороги на основі підходу глибокого активного навчання. Структура модулю зображена на рисунку 3.4.



Рисунок 3.4 – Структура модулю «прогнозування рівня забрудненості дороги»

Першим етапом функціонування інформаційної системи прогнозування динаміки забруднення доріг є попередня обробка вхідних даних.

На цьому кроці модуль попередньої обробки отримує на вхід часовий ряд зображень дорожнього покриття з модуля збору та підготовки даних. Зображення представлені у вигляді впорядкованої у часі послідовності, де кожне фіксує стан дорожнього покриття в певний момент часу з різним рівнем забрудненості.

Подальша обробка включає очищення даних від шумів, нормалізацію для поліпшення якості, розбиття на навчальні та тестові вибірки, а також формування додаткових лагових ознак на основі зсувів у часі. Після зазначених процедур дані передаються для побудови та навчання прогнозної LSTM-моделі.

Після початкового етапу завантаження та обробки вхідного часового ряду зображень, другим кроком є інтеграція допоміжної нейромережевої моделі визначення поточного рівня забрудненості доріг.

Ця переднавчена CNN-модель приймається з окремого модуля побудови та навчання моделей комп'ютерного зору для аналізу зображень. Інтеграція даної моделі дозволяє для кожного окремого зображення з вхідного часового ряду визначати відносний відсоток поточного рівня забрудненості дорожнього покриття.

Такий підхід надає додаткову інформацію про динаміку змін стану доріг у часі, що дозволяє покращити якість навчання та точність наступної LSTM-моделі прогнозування часових рядів забруднення доріг. Після додавання даних про відсоткові рівні забрудненості, часовий ряд передається на наступний модуль побудови прогнозної моделі.

На третьому етапі відбувається інтеграція результатів, отриманих на попередніх кроках, з метою побудови часового ряду рівня забрудненості зображень дорожнього покриття. Спочатку здійснюється об'єднання даних про виявлені об'єкти на зображеннях (перший крок) та результатів їх класифікації (другий крок). На основі кількості та типів ідентифікованих об'єктів, що можуть спричиняти забруднення (сміття, бруд, пошкодження покриття тощо), для кожного зображення розраховується інтегральний показник рівня забрудненості. Далі отримані показники

впорядковуються у часовій послідовності, формуючи часовий ряд динаміки забрудненості дорожнього покриття.

Після побудови згаданого часового ряду, його значення передаються до наступного, четвертого кроку, на якому за допомогою нейромережевої моделі здійснюватиметься прогнозування майбутніх значень рівня забрудненості дорожнього покриття.

На четвертому, заключному етапі модуля, вхідні дані у вигляді побудованого на попередньому кроці часового ряду динаміки рівня забрудненості дорожнього покриття подаються на вхід нейромережевої моделі прогнозування. За допомогою підходу глибокого активного навчання модель аналізує отримані часові ряди і здійснює прогноз майбутніх значень рівня забрудненості на заданий часовий проміжок.

Таким чином було розбито інформаційну систему на три модулі, щоб розділити завдання та полегшити розуміння програмної реалізації методу прогнозування забруднення доріг на основі підходу глибокого активного навчання. Було створено наступні модулі:

- модуль «Збільшення розмірності вхідних даних»;
- модуль «Визначення рівня забрудненості дороги на зображенні»;
- модуль «Прогнозування рівня забрудненості доріг»

3.2 Компоненти модулів інформаційної системи прогнозування забруднення доріг

Відповідно до розробленого методу прогнозування динаміки забруднення доріг на основі глибокого навчання та процедури визначення поточного рівня забрудненості за зображеннями, пропонується наступна архітектура інформаційної системи:

- модуль «Збільшення розмірності вхідних даних»;
- модуль «Визначення рівня забрудненості дороги на зображенні»;

- модуль «Прогнозування рівня забрудненості доріг»

Крім компонентів кожного з модулів, для модулю «Збільшення розмірності вхідних даних», необхідно створити датасет із зображеннями стану різних доріг у різний період часу. Створення такого датасету зумовлене низькою якістю і малою кількістю наявних потрібних для задачі даних у мережі Інтернет.

Тому для реалізації інформаційної системи було створено власний датасет із зображеннями доріг міста Хмельницького впродовж невеликого періоду:

- тестова вибірка містить по два зображення для кожного дня впродовж двох тижнів часу;
- валідаційна вибірка містить тридцять щоденних зображень однієї дороги в різний період часу;
- навчальна вибірка містить п'ятдесят чотири зображення, що робилися тричі на день впродовж вісімнадцяти днів.

Один з основних класів інформаційної системи прогнозування забруднення доріг – `load_data()` – клас, що відповідає за наступні задачі: завантаження архіву вхідних даних до системи; розархівування файл-архіву; розбиття набору даних на три відповідних теки – тренувальну, валідаційну, тестову; перейменування файлів у тестовій та валідаційній вибірці для окремого виділення відсотку забрудненості у назві файлів, а також відокремлення номера зображення, яке у назві файлу відповідає за порядковий часовий проміжок, в який було зроблено зображення.

Після завантаження, вхідні дані входять до компоненту системи, після чого виконується компонент – клас `load_and_preprocess_images()`, що відповідає за попередню обробку зображень до спільного розміру та подальше їх перетворення у вектори поточних даних і вектору лагів за допомогою значення зсуву.

Після проходження кожного з векторів через цей клас, вони потрапляють до класу нормалізації `img_scaler()`, на якому відбувається нормалізація зображень за ознаками за допомогою проходження 1D згортки крізь вхідні дані класу (у випадку методу

прогнозування забруднення – часовий ряд – вектори лагів та поточних даних), після чого два створених вектори конкатенуються.

Ще одним з класів є `perc_model()` в основі якого лежить нейромережева модель визначення відсотку забруднення на дорозі з зображення за допомогою CNN згорткового шару та LSTM-рекурентного шару. Вхідними даними результату є утворені внаслідок класу `load_and_preprocess_images()` вектори. Вихідним результатом є значення рівня забруднення дороги.

Останнім класом методу прогнозування забруднення дороги є `prognose_model()`, в основі якого – нейромережева модель для прогнозування забруднення на дорозі. Вхідні дані у вигляді часового ряду класу `img_scaler()` проходять крізь клас `load_and_preprocess_images()`, отримуючи значення рівня забрудненості для кожного з зображень у часовому ряді. Після цього отримані значення у вигляді нового вектору проходять пулінгові шари `MaxPooling`, LSTM шар, Повнозв'язний нейронний шар та функцію лінійної активації `ReLU` для отримання прогнозованого результату на певний проміжок часу вперед. Кількість ітерацій навчання моделі та кількість пройдених проміжків часу для прогнозу у майбутнє вказуються у коді раніше.

Таким чином, було розроблено необхідні компоненти системи прогнозування рівня забруднення доріг на основі підходу глибокого активного навчання, що потрібні для програмної реалізації модулів збільшення розмірності вхідних даних, визначення рівня забрудненості доріг з зображення, прогнозування забруднення дороги. Було розроблено класи, що можуть бути застосовані у програмній реалізації шлях кодування.

3.3 Проєктування програмних засобів для прогнозування забруднення доріг

Для прогнозування забруднення доріг на основі підходу глибокого активного навчання, з використанням різних нейромережевих моделей, доцільно використати

спеціалізовані програмні розширення у вигляді бібліотек до мови програмування Python [21].

Python має велику кількість різноманітних бібліотек, які значно розширюють можливості мови і спрощують розробку застосунків. Бібліотеки Python стають у пригоді при обмеженості в часі, повторному використанню коду, спрощенні складних завдань.

Для підходу глибокого активного навчання бібліотеки мови також стають у потребі. Однією з таких бібліотек є TensorFlow - це популярна open-source бібліотека машинного навчання, яка широко використовується для розробки алгоритмів глибокого навчання. Надає можливості для побудови і тренування нейронних мереж, які лежать в основі глибокого навчання. Має розвинуті засоби для розподілених обчислень. Доступні готові моделі (CNN, LSTM тощо) для різних популярних задач задач.

Також у розробці використовується бібліотека Keras - це популярна нейромережева бібліотека для Python, яка надає зручний і простий у використанні інтерфейс до бібліотек глибокого навчання, таких як TensorFlow, CNTK або Theano. Ось деякі основні характеристики Keras: простота та зручність - Keras має інтуїтивно зрозумілий API, що дозволяє швидко конструювати і тренувати нейронні мережі різних архітектур; модульність та розширюваність - Keras містить реалізації популярних мережевих шарів, функцій активації, оптимізаторів, які можна комбінувати і розширювати; незалежність від платформи - моделі Keras працюватимуть без змін на CPU та GPU, в середовищах TensorFlow, CNTK, Theano; підтримка конвеєрів обробки даних - зручного і ефективного способу обробки і подання даних для тренування.

SKlearn (scikit-learn) - надзвичайно популярна Python бібліотека для машинного навчання та аналізу даних. Ось її основні характеристики:

Простота використання. SKlearn має зручний API, що дозволяє швидко будувати моделі машинного навчання: класифікації, регресії, кластеризації.

Модульність. Бібліотека поділена на окремі модулі за типами алгоритмів і задач машинного навчання. Це зручно для вивчення і використання лише потрібних алгоритмів.

Широка вибірка алгоритмів машинного навчання: лінійна та логістична регресія, метод опорних векторів, дерева рішень, випадковий ліс, наївний Байєсівський класифікатор тощо.

Ефективність та масштабованість. Алгоритми оптимізовані для роботи як з малими, так і з величезними наборами даних, включають керування пам'яттю, паралельні обчислення.

Переваги таких бібліотек як TensorFlow, Keras та SKlearn доцільні для використання при завданні у прогнозуванні забруднення доріг, адже активно користуються підходом як глибокого, так і активного навчання. Це дозволяє використовувати їх і при підході глибокого активного навчання для полегшення своїх же дій.

Крім бібліотек, призначених для роботи з нейромережами, штучним інтелектом, глибоким та активним навчанням, також були використані звичайні системні бібліотеки **zipfile** – для роботи з архівними файлами, **os** – для розбиття вибірок на три окремі папки та **NumPy** – фундаментальна бібліотека для наукових обчислень, що дозволяє:

- ефективно працювати з багатовимірними масивами й матрицями (для зображень на часовому ряді);
- використовувати велику кількість описаних математичних функцій;
- працювати зі зручним, подібним до математичної мови синтаксисом при роботі з багатовимірними даними.

Таким чином, для вирішення завдання кваліфікаційної роботи магістра, крім мови Python також використовуються її розширення (бібліотеки) TensorFlow, Keras, SKlearn та інші. Вони значно полегшують роботу з кодом і оптимізують роботу усього методу.

Висновок до розділу 3

У третьому розділі було розроблено інформаційну систему програмного забезпечення для реалізації методу прогнозування забруднення доріг на основі підходу глибокого активного навчання.

Інформаційну систему було поділено на три основні модулі:

- модуль збільшення розмірності вхідних даних. Призначений для попередньої обробки початкового набору цифрових зображень доріг. Даний модуль реалізує перетворення зображень на векторні представлення більш високої розмірності, які міститимуть додаткові інформативні ознаки, що відображають візуальний контент кожного зображення. Застосування збільшення розмірності дозволяє істотно покращити якість подальшого аналізу даних та прогнозування рівня забруднення з використанням методів глибокого навчання, оскільки такі методи демонструють кращу ефективність на даних з більшим обсягом інформативних ознак.

- модуль визначення поточного рівня забрудненості дороги. Для аналізу попередньо оброблених векторних представлень вхідних зображень та прогнозування рівня забруднення на кожному окремому зображенні розроблено функціональний модуль на основі гібридної нейронної мережі з використанням LSTM (Long Short-Term Memory - довгострокова короткочасна пам'ять) шарів та повнозв'язаних шарів. LSTM шари дозволяють враховувати послідовні залежності між вхідними даними, а повнозв'язані шари виконують безпосереднє перетворення даних та прогнозування цільового значення у відсотках - рівня забруднення зображення. Така архітектура нейронної мережі є оптимальною для вирішення поставленого завдання прогнозування.

- модуль прогнозування майбутнього рівня забрудненості доріг. Для прогнозування майбутніх значень рівня забруднення на основі динамічних рядів вхідних даних розроблено окремий функціональний модуль, що використовує попередньо натреновану нейромережеву модель глибокого навчання. Даний модуль аналізує вхідні послідовності вимірів рівня забрудненості у часі, виявляє

закономірності зміни цих даних та на основі вилучених статистичних залежностей здійснює прогнозування числових значень цільового показника на задану кількість кроків вперед. Використання попередньо натренованої нейромережевої моделі дозволяє підвищити точність прогнозних розрахунків порівняно з традиційними статистичними підходами.

Для кожного функціонального модуля розробленої системи було формалізовано його конкретне призначення, визначено основні етапи обробки даних та специфіковано формат вхідних та вихідних даних. Така декомпозиція на окремі модулі з чітко визначеними інтерфейсами дозволяє спростити загальне проектування системи та подальшу програмну реалізацію її компонентів.

Крім того, було розроблено концептуальні моделі основних програмних компонентів (класів), необхідних для реалізації кожного з функціональних модулів системи. Визначення таких моделей надає загальне уявлення про архітектуру та структурні взаємозв'язки між програмними одиницями розроблюваної системи ще до початку їх безпосередньої реалізації, що спрощує подальше програмування.

В якості програмної платформи для реалізації розроблюваної системи обрано мову програмування Python та спеціалізовані бібліотеки машинного навчання, такі як TensorFlow, Keras, NumPy та інші. Зазначені програмні засоби містять широкий інструментарій для розробки та впровадження моделей глибокого навчання, що є оптимальним вибором для вирішення поставленого завдання прогнозування рівня забруднення.

Отже, у даному розділі виконано проектування запропонованої інформаційної системи та її ключових програмних модулів, формалізовано їх функціональне призначення та визначено формати вхідних і вихідних даних. Це дозволяє перейти до наступного етапу - безпосередньої програмної реалізації розробленого методу прогнозування рівня забруднення автомобільних доріг на основі технологій глибокого навчання.

Розділ 4 Дослідження ефективності методу прогнозування забруднення доріг на основі підходу глибокого активного навчання

4.1 Створення датасету для дослідження ефективності методу

Для проведення майбутнього дослідження ефективності методу прогнозування забруднення доріг було використано набір даних із зображеннями доріг, в який входить набір зображень однієї і тої самої дороги в різних період часу і з різним відсотком забруднення.

У набір датасету увійшли зображення доріг обласного центру Хмельницької області – міста Хмельницького, Україна.

Фото були зроблені у різний період часу протягом доби у різні дні тижня. Такий набір зображень дозволить краще тренувати модель за декількох причин: різні умови на дорозі - забрудненість, освітлення, якість дорожнього покриття тощо; різний часовий проміжок, що надає можливість скласти усі зображення у єдиний послідовний часовий ряд.

Приклади фото зображені на рисунку 4.1



Рисунок 4.1 – Приклади фото з набору даних

За підходом до збільшення розмірності даних, створений набір даних спочатку проходить перетворення у вектор поточних даних, після чого за допомогою часових лагів утворюється другий вектор. Наступним кроком стане перетворення векторів у вектори ознак за допомогою гіперпараметрів зміни розміру зображення та фільтру 1D згорткового шару.

На цьому етапі зображення виглядають несприйнятними для людського ока, але набагато легшими для роботи нейромережевих моделей (рисунок 4.2 і 4.3)




Рисунок 4.2 – Перетворене зображення з чистою дорогою



Рисунок 4.3 – Перетворене зображення з забрудненістю

Хоч перетворені зображення виглядають не так, як оригінальні, людське око теж може побачити дефекти на забрудненій дорозі. У випадку з представленим зображенням, чітко можна побачити найбільші дефекти на дорозі у вигляді рідинних відходів. На цих місцях присутні найбільш розмиті ефекти.

Таким чином, було скомплектовано набір даних, що складаються із зображень доріг з різними рівнями забрудненості та різними умовами – погодні умови, освітлення тощо. Дані було перетворено у вектори, завдяки чому було отримано часовий ряд для подальших досліджень ефективності моделей та методу в цілому.

4.2 Дослідження ефективності методу прогнозування забруднення доріг на основі підходу глибокого активного навчання

Для оцінки ефективності розробленого методу прогнозування забруднення доріг було проведено дослідження точності прогнозування відносно різної кількості епох (ітерацій) навчання нейромережевої моделі. Суть дослідження полягала у порівнянні точності прогнозів забруднення доріг при різних значеннях кількості навчальних ітерацій моделі.

Під час експериментів використовувались різні значення кількості епох навчання в діапазоні від 10 до 700. Для кожного значення кількості епох фіксувалась точність прогнозування забруднення доріг на тестовій вибірці даних за метрикою MAE. На основі отриманих результатів будувалась залежність значень точності прогнозування від кількості навчальних ітерацій моделі. Аналіз отриманих кривих дозволив визначити оптимальне значення кількості епох навчання, при якому досягається найвища точність прогнозних розрахунків.

Дослідження було проведено за допомогою функції середньої абсолютної помилки MAE (Mean Absolute Error), що є поширеним методом оцінки точності прогнозів моделі машинного навчання.

У дослідженні MAE використовується наступним чином:

1) маємо часовий ряд вимірів рівня забрудненості доріг у минулому (у вигляді числових значень).

2) тренуємо нейронну мережу прогнозувати рівень забруднення на певну кількість кроків вперед на основі попередніх даних.

3) обчислюємо MAE між прогнозами моделі для тестових даних та реальними майбутніми значеннями рівня забрудненості (зображення були зроблені після останніх у тестовій вибірці).

4) аналізуємо динаміку зміни MAE протягом навчання - кількості епох. Зменшення MAE означає, що модель краще навчається прогнозувати майбутнє.

Тобто, спочатку беремо перше прогнозування моделі при навчанні (першу ітерацію) і знаходимо різницю між фактичним та прогнозним значенням для цього вимірювання: $r = y_i - \hat{y}_i$.

Після цього знаходимо абсолютне (модульне) значення цієї різниці $R = |r|$. І додаємо це значення до суми абсолютних різниць для всіх вимірювань від 1 до n , де n – це кількість ітерацій (епох) навчання. І в кінці отримуємо середнє абсолютне відхилення MAE.

Для знаходження відсотку точності дослідження x , для функції MAE необхідно використати наступну формулу:

$$x\% = (1 - (MAE * ei)) * 100\%$$

де: MAE – середнє абсолютне відхилення,

ei – діапазон можливих значень забруднення (у нашому випадку – від 0 до 100).

Отримані результати дослідження представлені в таблиці 4.1

Таблиця 4.1 – результати дослідження

Кількість епох навчання	Точність прогнозування тренувальної вибірки у відсотках	Точність прогнозування валідаційної вибірки у відсотках	Час витрачений на навчання моделі
10	1.24	0.86	22 секунди
50	56.96	53.44	1 хвилина 0.8 секунд
150	64.31	62.52	2 хвилини 37 секунд
300	76.12	72.04	5 хвилин 9 секунд
450	85.47	80.89	8 хвилин 24 секунди
700	97.84	91.92	12 хвилин 24 секунди

Аналіз результатів, отриманих у ході проведення дослідження точності прогнозування забруднення доріг на основі підходу глибокого активного навчання можна помітити залежність між кількістю епох і якістю навчання у вигляді результатів точності такого навчання. Більша кількість епох = більшій точності і збільшеному часу для тренування моделі (рисунок 4.4)




Рисунок 4.4 – Діаграма порівняння точності прогнозування рівня забруднення дороги до кількості навчальних епох у %

Також варто врахувати стабільне відношення валідаційного набору до тренувального. У випадку, якщо валідаційна точність буде значно нижче за тренувальну – це ознака перенавчання.

Отже, для оцінки ефективності методу прогнозування забруднення доріг було проведено дослідження точності прогнозів за допомогою функції середньої абсолютної помилки MAE. Дослідження показали, що збільшення кількості періодів навчання (епох), через які проходять дані, відповідно підвищує точність визначення рівня забруднення доріг. Наприклад, коли протягом періоду дослідження було

проаналізовано 10 зразків відповідних параметрів, точність прогнозу становила 1,24%, але коли було проаналізовано 700 зразків, точність прогнозу зросла до 97,84%.

4.3 Дослідження ефективності нейромережевої моделі визначення рівня забрудненості дороги на зображенні

Для комплексної оцінки ефективності розробленого методу прогнозування забруднення доріг на основі глибокого активного навчання, було також проведено дослідження щодо ефективності визначення поточного рівня забрудненості доріг за зображеннями. Адже для подальшого точного прогнозування динаміки забруднення необхідно спочатку отримати максимально точні дані про поточний стан дорожнього покриття.

Для оцінки ефективності даного етапу використовувалась функція похибки RMSE (Root Mean Square Error). Суть роботи RMSE для дослідження ефективності і точності полягає у вирахуванні значення метрики між реальним рівнем забрудненості на зображенні та тим, що були отримані моделлю під час навчання. Навчання відбувається протягом декількох ітерацій (епох), а отже значення RMSE ми можемо отримати після кожної пройдені епохи.

Для отримання значення RMSE потрібні наступні кроки:

і. визначити різницю між реальним та отриманим моделлю значенням забрудненості: $ei = yi - Yi$, де: ei – різниця значень, yi – реальне значення, Yi – отримане моделлю значення;

2) знайти суму всіх квадратів різниць значень для кожного з вимірювань: $(ei)^2$;

3) додати квадрати всіх значень, отриманих в процесі навчання і поділити їх на кількість, отримавши результат Av : $(\sum(ei)^2) / n$;

4) отримати значення RMSE для однієї епохи за допомогою квадратного кореню з Av : $RMSE = \sqrt{Av}$.

Для отримання відсоткового значення x достатньо виконати просту дію:

$$x\% = (1 - \sqrt{Av}) * 100\%$$

Графік залежності RMSE від кількості епох дозволяє оцінити швидкість та якість навчання моделі. Зниження RMSE, або ж підвищення результату точності у відсотках, з ростом кількості ітерацій вказує на поліпшення роботи та ефективності моделі.

Саме таким чином аналіз динаміки RMSE дає кількісну оцінку ефективності навчання будь-якої нейромережі. Отримані результати дописані в таблиці 4.7

Таблиця 4.2 – результати дослідження ефективності нейромережевої моделі

Кількість епох навчання	Точність визначень тренувальної вибірки у відсотках	Точність визначень валідаційної вибірки у відсотках	Час витрачений на навчання моделі
10	16,27	15,64	1 хвилина 52 секунди
50	52,48	50,32	4 хвилини 31 секунда
150	78,75	75,36	10 хвилин 12 секунд
300	85,92	84,81	17 хвилин 27 секунд
450	94,10	93,67	25 хвилин 38 секунд
700	98,42	97,95	34 хвилини 2 секунди

Аналіз результатів, що були отримані у процесі проведення дослідження точності прогнозування рівня забрудненості дороги з зображення за допомогою нейромережевої моделі, що працює на зготкових CNN шарах, та LSTM-рекурентних шарах, можна помітити залежність між кількістю епох і якістю навчання у вигляді

результатів точності такого навчання. Більша кількість епох відповідає більшій точності і збільшеному часу для тренування моделі (рисунок 4.5)




Рисунок 4.5 – Діаграма порівняння точності визначення рівня забруднення дороги до кількості навчальних епох у %

Стабільне відношення валідаційного набору до тренувального також варто врахувати при цьому дослідженні. Ознака перенавчання у вигляді значно нижчої валідаційної точності – відсутня.

Таким чином, отримані результати за метрикою RMSE на тестових даних дозволили оцінити ефективність методу визначення поточного рівня забрудненості та вплив точності цього етапу на загальну точність прогнозування динаміки забруднення доріг.

Дослідження показали, що збільшення кількості епох навчання для пошуку рівня забрудненості дороги з зображення, явно підвищує якість такого навчання. До прикладу - коли протягом періоду дослідження було проаналізовано навчання при 10

ітераціях, точність прогнозу для тестової та валідаційної вибірок становила 16,27% та 15.64%, але коли було проаналізовано 700 епох, точність прогнозу зросла до 98,42% та 97.95% відповідно.

4.4 Програмна реалізація модуля прогнозування забруднення доріг на основі підходу глибокого активного навчання

Для програмної реалізації модуля прогнозування забруднення доріг на основі підходу глибокого активного навчання використано мову програмування Python з усіма необхідними бібліотеками: TensorFlow, SKlearn, NumPy. Уся реалізація виконана у хмарному середовищі розробки Google Colab, що виділяє машину з характеристиками 13 Гб оперативної пам'яті, процесор Intel Xeon, графічне ядро NVidia Tesla K80, що відкриває кращі можливості для роботи зі штучним інтелектом та нейронними мережами, що використовуються в роботі.

Для роботи методу прогнозування забруднення доріг на основі підходу глибокого активного навчання необхідно створити програмну реалізацію наступних компонентів (частин):

1) програмна реалізація підходу до збільшення розмірності вхідних даних за допомогою згорткових мереж і часових лагів.

2) програмна реалізація нейромережевої моделі визначення рівня забрудненості на дорогах за допомогою зображень.

3) програмна реалізація нейромережевої моделі прогнозування забруднення доріг на основі підходу глибокого активного навчання.

4.4.1 Програмна реалізація модуля збільшення розмірності вхідних даних за допомогою згорткових мереж і часових лагів

Першим модулем для програмної реалізації є модуль «збільшення розмірності вхідних даних за допомогою згорткових мереж і часових лагів», вихідними

результатами якого стануть оброблені дані для подальшого їх використання у суцільній розробленій системі.

Методом прогнозування забруднення доріг використовується підхід до збільшення розмірності вхідних даних за допомогою згорткових мереж і часових лагів, що полягає у перетворенні набору даних на вектор, який додатково ще утворює вектор лагів. Після цього через кожен вектор проходить фільтр 1D згортки, і виконується конкатенація двох векторів у один часовий ряд.

Підготовані на 3 вибірки – навчальну, валідаційну та тестову – дані формують у архів, окремо розподіливши дані по текам з відповідними назвами. У ході реалізації такого підходу, дані було сформовано і підготовано власноруч через обмеженість кількості потрібних за задачею датасетів. Так, усі зображення доріг були завантажені до хмарного ресурсу, після чого були завантажені, зчитані та збережені у середовищі Google Colab:

```
# Завантаження zip файлу з GitHub
url = 'https://github.com/user/directory/raw/main/data.zip'
response = requests.get(url)
with ZipFile(BytesIO(response.content), 'r') as zip_ref:
    zip_ref.extractall('your_dataset_directory')

# Завантаження, розподіл та збереження даних
train_dir = 'your_dataset_directory/train'
val_dir = 'your_dataset_directory/val'
test_dir = 'your_dataset_directory/test'
```

Після цього завантажені та підготовані по вибіркам дані мають бути перетворені у вектори. Таким чином знову має відбуватися завантаження даних, але вже з папок системи. Після цього дані мають перемішатися та вже тільки потім перетворені на вектори X_{train} , X_{val} та X_{test} . Для цих трьох задач доцільно скористатися NumPy – бібліотекою для Python.

Наступним кроком є створення векторів з лагами, що збільшує вибірку даних. Для цього необхідно визначити розмір лагу (кількість відліків) та створити лаги для кожного з векторів:

```
# Створимо лаги для X_train
X_train_lags = []
for i in range(lag_size):
    X_train_lags.append(X_train[:-i])
X_train_lags = np.hstack(X_train_lags)
```

За підходом до збільшення розмірності вхідних даних вектори мають бути пройдені 1D згорткою нейромережі CNN, що дозволить перетворити дані на більш придатний для моделювання вигляд.

Потрібно додати 1D згортку з обраною кількістю фільтрів та певним розміром ядра і застосувати їх до вхідних даних, щоб отримати вектори ознак. Для цього створюється модель, до якої додаються:

- 1D згортковий шар;
- функція втрати MSE;
- оптимізатор Adam.

```
# Створюємо модель
model = Sequential()
# Додаємо 1D згортковий шар
model.add(Conv1D(filters=32, kernel_size=3, activation='relu',
input_shape=(n_lags, n_features)))
# Компілюємо модель
model.compile(loss='mse', optimizer='adam')
```

Після використання моделі на кожного з векторів вектори оригінальних даних та вектори лагів будуть перетворені у вектори ознак шляхом конкатенації у один єдиний вектор за допомогою функції `concatenate` бібліотеки NumPy, окремо для кожної вибірки `X_train_final`, `X_val_final` та `X_test_final`. Такий вектор називають часовим рядом, який часто застосовується у глибокому активному навчанні для якісної обробки і навчання моделі на даних.

Таким чином, на виході програмної реалізації підходу до збільшення розмірності вхідних даних на основі глибокого активного навчання отримуємо часовий ряд, який ефективно працює з нейромережевими моделями.

4.4.2 Програмна реалізація модуля визначення рівня забруднення доріг на основі підходу глибокого активного навчання

Для розробки методу прогнозування забруднення доріг на основі глибокого активного навчання також необхідно враховувати доцільність визначення рівня забрудненості.

Так як для визначення рівня забрудненості доріг необхідно для подальшого прогнозування рівня забруднення доріг постає необхідність у використанні часового ряду, так як дані мають змінюватися з часом, то доцільно використати дані, які було отримано підходом збільшення розмірності вхідних даних.

Вхідними даними на цьому етапі програмної реалізації будуть вихідні дані підходу до збільшення розмірності даних на основі глибокого активного навчання, тобто часовий ряд, що є конкатенованим вектором із векторів: ознак лагів, ознак оригінальних даних з зображень доріг.

Другим кроком стане передача вхідних даних до LSTM-рекурентного шару, який аналізує послідовність, встановлюючи зв'язки між зображеннями та запам'ятовуючи контекст.

А на основі кожного попереднього зображення в ряді, LSTM-рекурентний шар спостерігає за рівнем зміни та робить припущення щодо рівня забрудненості на поточному. Це дозволяє навчити модель і передати оцінений вектор ознак до повнозв'язного шару.

Кожен вузол повнозв'язного шару використовується для отримання конкретного прогнозу рівня забрудненості на основі даних від LSTM, приймаючи на вхід вектор ознак від нього.

Цей вектор ознак множиться на ваги зв'язків даного вузла, що дозволяє кожному вузлу шару обчислювати деяке проміжне значення на основі вхідних даних. Останній сигмоїдний вузол комбінує отримані результати та видає один кінцевий прогноз – рівень забрудненості дороги на зображенні.

За допомогою саме цих функцій і відбувається навчання моделі, що додатково використовує функцію втрати MSE, оптимізатор Adam та метрику точності:

```
# LSTM частина
model.add(LSTM(64))

# Повнозв'язний шар
model.add(Dense(1, activation='sigmoid'))

# Компіляція
model.compile(loss='mse',
              optimizer='adam',
              metrics=['accuracy'])

# Навчання
model.fit(X_train, y_train,
         epochs=100,
         validation_data=(X_val, y_val))
```

Таким чином сукупність об'єднаного вектору ознак, створеного на підході глибокого активного навчання, в поєднанні з LSTM-рекурентим на повнозв'язним шарами, дає можливість у створенні навчальної моделі, що здатна визначати рівень забрудненості дороги на зображенні від низького рівня до екстремального, де:

- 0-20% забрудненості - низький рівень
- 20-40% забрудненості - помірний рівень
- 40-60% забрудненості - високий рівень
- 60-80% забрудненості - дуже високий рівень
- 80-100% забрудненості - екстремальний рівень

Приклад вихідних даних з зображенням результатом на рисунках 4.6 і 4.7

Рівень забруднення: низький, Точність: 94.58%



Рисунок 4.6 – Визначення рівня забруднення на звичайному зображенні

Рівень забруднення: помірний, Точність: 76.92%




Рисунок 4.7 – Визначення рівня забруднення на зображенні з перешкодами (погана якість зображення, нічне світло)

Вихідними даними цієї моделі є рівень забрудненості доріг у вигляді відсотків (на скільки забруднена дорога). Приклади роботи моделі на зображеннях показують,

що модель працює вірно та точно. Для звичайного зображення модель без перешкод справилася з задачею і дала правильну оцінку рівня забрудненості. Для зображення вночі модель теж справилася вірно, побачивши забрудненості у вигляді залишку води від дощу і оцінивши рівень забрудненість як помірну.

Таким чином, модель працює вірно і надає вихідні результати, які в поєднанні з часовим рядом стануть вхідними даними для створеної моделі прогнозування рівня забрудненості доріг.

4.4.3 Програмна реалізація модуля прогнозування рівня забруднення доріг на основі підходу глибокого активного навчання

Останній модуль «прогнозування рівня забруднення доріг на основі глибокого активного навчання» - головна мета кваліфікаційної роботи магістра. Працюючий модуль дозволить отримувати прогнози забруднення довколишнього середовища (дороги) на основі збірки даних із зображень, що були зроблені у певний проміжок часу на одній дорозі.

В основі програмної реалізації модуля лежить нейромережева модель, що комбінує CNN і LSTM.

На початку модель завантажує вхідні дані у вигляді у вигляді послідовності зображень (часового ряду) за допомогою ImageDataGenerator, який попередньо ще раз проходить через попередню модель витягнення ознак з ряду для визначення рівня забрудненості на кожному часовому моменті. Після чого повертає дані у вигляді результатів рівня забруднення знов до обробки, попередньо розбившись на вхід (X) та вихід (y) для навчання моделі:

```
# Витягуємо ознаки з зображень за допомогою CNN
cnn_model = model #попередньо навчена CNN для екстракції ознак
X_current = cnn_model.predict(images)
X_train, y_train = X[:-1], X[1:]
```

Після цього створюється сама модель, яка працює виключно на рекурентному шарі LSTM для вилучення ознак саме прогнозу:

```
# Створюємо модель
model = Sequential()
model.add(LSTM(32, input_shape=(X_train.shape[1], X_train.shape[2])))
model.add(Dense(1, activation='linear'))

# Навчаємо модель
model.compile(loss='mse', optimizer='adam')
model.fit(X_train, y_train, epochs=100)
```

Процес побудови моделі прогнозування динаміки забруднення доріг включає етап попередньої підготовки даних та безпосередньо навчання рекурентної нейронної мережі LSTM (Long Short-Term Memory).

На основі підготовленого набору даних у вигляді часових рядів зображень відбувається безпосереднє навчання моделі LSTM з використанням фреймворку Keras та бекенду TensorFlow у середовищі мови програмування Python.

Після завершення багатоітераційного процесу навчання отримуємо фінальну навчену LSTM-модель, яка може застосовуватись для отримання прогнозних даних. За допомогою функції `.predict()` подаємо на вхід моделі вихідний часовий ряд, для якого бажаємо отримати прогноз, та отримуємо результат у вигляді майбутніх значень цього часового ряду.

```
# Створюємо модель
model = Sequential()
model.add(LSTM(32, input_shape=(X_train.shape[1], X_train.shape[2])))
model.add(Dense(1, activation='linear'))
```

Розроблена модель прогнозування динаміки рівня забрудненості доріг на основі аналізу часових рядів зображень генерує результат у вигляді кількісного значення зміни у відсотках.

Наприклад, при моделюванні на основі даних за попередній тиждень, модель аналізує вхідну часову послідовність зображень і прогнозує відсоткове значення зміни рівня забрудненості на наступний момент часу.

Для зручної інтерпретації кінцевим користувачем, передбачено візуалізацію у вигляді текстового повідомлення: "Згідно з поставленою часовою варіативністю

зображень, забрудненість на дорогах наступний раз зміниться на: $x\%$ ", де x - це прогнозне відсоткове значення зміни рівня забрудненості.

Така форма подання дозволяє легко зрозуміти результати роботи моделі та використати їх на практиці для вироблення рішень щодо необхідності прибирання доріг.

Таким чином, було розроблено програмну реалізацію модулю «Прогнозування рівня забруднення доріг», яке працює за дослідженим у роботі методом прогнозування забруднення доріг на основі підходу глибокого активного навчання. Отримані результати показують прогнозовану зміну у рівні забрудненості доріг у вигляді відсотків (від -100% до $+100\%$), де від'ємне значення означає, що дорога стане чистішою в наступний період часу, а додатне – забрудненішою.

Висновки до розділу 4

В розділі 4 досліджено комплектування датасету із зображень з дорогами (як забрудненими, так і чистими) у різний період часу. Також було розглянуто який вигляд матимуть такі зображення при перетворенні, як виглядають дефекти на дорогах та чим вони відрізняються від чистих.

Для оцінки ефективності методу прогнозування рівня забруднення доріг на основі підходу глибокого активного навчання було використано функцію середньої абсолютної помилки MAE, що у результаті дослідження показала середній відсоток точності прогнозування. А для дослідження нейромережевої моделі визначення рівня забрудненості на дорозі з зображення було використано функцію середньоквадратичної похибки RMSE, що також показала середнє значення точності визначення рівня забрудненості при навчанні.

Також додатково були проведені зміни такого параметру, як кількість ітерацій навчання моделі, що несуттєво змінює отримані результати. Кількість втрат при збільшенні ітерацій зменшується, а кількість часу витраченого на це збільшується. Проведені дослідження встановили, що при збільшенні кількості досліджуваних епох (ітерацій) у вигляді вибірок параметрів даних за максимально можливий

встановлений діапазон, призводить до підвищення точності прогнозування рівня забруднення доріг.

Послідовна реалізація кожного модуля інформаційної системи отримала позитивні результати за допомогою вхідних даних, роботи над ними і виведення результатів.

Загальні висновки

Кваліфікаційна робота магістра розв'язує наукову задачу прогнозування забруднення доріг на основі підходу глибокого активного навчання, для чого було розроблено підхід до визначення рівня забрудненості дороги з використанням зображень та використано нейромережеву модель для прогнозування рівня забруднення дороги на основі вхідних даних у вигляді часового ряду із зображень, що були зроблені в певний період спостерігання. Для реалізації такого методу було розроблено відповідні програмні засоби.

За результатом виконання роботи були поставлені та вирішені наступні завдання:

- розроблено метод прогнозування забруднення доріг на основі підходу глибокого активного навчання.
- проведено аналіз моделей та методів прогнозування забруднення доріг.
- проведено експерименти та проаналізовано ефективність методу.

В результаті роботи були отримані наступні інновації й положення наукової новизни.

1. Запропоновано метод прогнозування забруднення доріг на основі глибокого активного навчання, який дозволяє за вхідними даними у вигляді зображень одержувати результат у вигляді прогнозованої оцінки рівня забрудненості дороги у майбутньому.

2. Вдосконалено метод визначення рівня забрудненості доріг з зображень за допомогою поєднання нейромережевих структур LSTM та CNN, що дозволяє з високою точністю оцінити та отримати як результат рівень забрудненості дороги на зображенні у відсотках.

Для проведення подальших досліджень було сформовано датасет на основі зображень доріг міста Хмельницький Хмельницької області, Україна. Датасет містить три вибірки:

- тренувальна вибірка – призначена для навчання моделі глибокого навчання.
- валідаційна вибірка – використовується для налаштування гіперпараметрів і моніторингу якості навчання моделі.
- тестувальна вибірка – застосовується для остаточної оцінки якості навченої моделі.

Зображення в датасеті були отримані на різних дорогах міста протягом трьох тижнів у різний час доби (двічі на день). Така процедура формування вибірок дозволила забезпечити представлення різних станів дорожнього покриття за різних погодних та інших умов експлуатації для навчання та тестування моделі. Отриманий датасет став основою для подальшого дослідження методів визначення та прогнозування рівня забрудненості доріг.

Для практичної реалізації розробленого методу прогнозування забруднення доріг було створено програмне забезпечення з використанням мови програмування Python та її спеціалізованих бібліотек для машинного навчання.

Архітектура програмного забезпечення складається з окремих модулів для завантаження даних, попередньої обробки зображень, побудови і навчання моделей глибокого навчання, а також формування прогнозів і їх візуалізації.

Для реалізації нейронної мережі було обрано бібліотеку Keras на основі backend TensorFlow. Дана бібліотека надає зручний API для швидкої розробки глибоких нейронних мереж.

Для попередньої обробки даних, формування навчальних вибірок та оцінки метрик якості використовувались інструменти бібліотек NumPy, Scikit-Learn. За допомогою даних бібліотек було ефективно реалізовано всі етапи методу прогнозування - від завантаження вхідних даних до візуалізації кінцевих прогнозів.

Для оцінки ефективності розробленого методу прогнозування забруднення доріг на основі глибокого активного навчання було проведено низку досліджень.

Для кількісної оцінки точності та ефективності розробленого методу прогнозування забруднення доріг на основі підходу глибокого активного навчання

було використано функцію середньої абсолютної похибки MAE (Mean Absolute Error).

Застосування саме цієї функції похибки обумовлено тим, що вона дає змогу обчислити усереднене за модулем відхилення прогнозних значень рівня забрудненості, які генерує розроблена нейромережева модель на основі аналізу попередніх даних, від реальних показників забрудненості доріг у тестовий період. Значення MAE відображає здатність моделі точно передбачати майбутній стан об'єкта моделювання, а його мінімізація є однією з ключових задач під час розробки та налаштування систем прогнозної аналітики.

З метою оцінки точності та якості розробленої нейромережевої моделі визначення поточного рівня забрудненості дороги на основі аналізу зображень на основі підходу глибокого активного навчання було застосовано функцію кореня середньоквадратичної похибки або RMSE (Root Mean Square Error).

Дана функція дозволяє розрахувати середнє відхилення значень, отриманих на виході моделі, від реальних (еталонних) даних, що використовувались під час її навчання. Таким чином, чим меншим є значення показника RMSE, тим вищою є загальна точність та якість побудованої моделі у даній предметній галузі.

Проведені в процесі дослідження експерименти з метою оцінки ефективності запропонованого методу прогнозування забруднення доріг на основі підходу глибокого активного навчання показали, що із збільшенням кількості епох (періодів) навчання розробленої нейромережевої моделі спостерігається поступове, але стійке зменшення значень функції втрат та середньоквадратичної похибки прогнозу, які є ключовими критеріями оцінювання точності та якості моделі.

Отримані результати дозволяють зробити висновок, що подовження процесу навчання моделі, тобто збільшення кількості епох шляхом багаторазового аналізу та корегування вагових коефіцієнтів нейромережі, позитивно впливає на точність прогнозних розрахунків рівня забруднення на заданий майбутній період. Таким чином можна стверджувати, що запропонований підхід є ефективним для вирішення поставленого завдання.

Також дослідження підтвердили ефективність запропонованого методу на основі глибокого активного навчання для вирішення поставленої задачі прогнозування забруднення доріг. Наприклад, коли протягом періоду дослідження методу прогнозування рівня забруднення доріг було проаналізовано 10 зразків відповідних параметрів, точність прогнозу становила 1,24%, але коли було проаналізовано 700 зразків, точність прогнозу зросла до 97,84%.

Наукові й практичні результати кваліфікаційної роботи магістра описані у тезах, які було одержано та включено до Збірника наукових праць Конференції АПКН-2023.

Перелік джерел

1. Alessandra Rossi, Meiyin Wu, Bernabas T. Wolde, Kevin W. Zerbe, Tsung-Ta David Hsu, Ariane Giudicelli, Rosana Da Silva / Understanding the factors affecting the quantity and composition of street litter: Implication for management practices, URL: <https://www.sciencedirect.com/science/article/pii/S2405844023014524#bib6>
2. Про сміття та відходи в Україні, URL: <https://biz.nv.ua/ukr/markets/smittyia-i-vidhodi-shcho-z-nimi-roblyat-v-ukrajini-a-shcho-u-rozvinenih-krajinah-svitu-infografika-50161387.html>
3. Pedram Saeidizand, Koos Fransen, Kobe Boussauw / Revisiting car dependency: A worldwide analysis of car travel in global metropolitan areas, URL: <https://www.sciencedirect.com/science/article/abs/pii/S0264275121003668>
4. Дарина Синицька / Прибирання в обласних центрах країни: хто, кому та скільки платить за чисті вулиці, URL: <https://dozorro.org/blog/pribirannya-v-oblasnih-centrah-krajini-hto-komu-ta-skilki-platit-za-chisti-vulici>
5. Mohammad AlElaiwi, Mugahed A. Al-antari, Hafiz Farooq Ahmad, Areeba Azhar, Badar Almarri, Jamil Hussain / Mathematics | Free Full-Text | VPP: Visual Pollution Prediction Framework Based on a Deep Active Learning Approach Using Public Road Images, URL: <https://www.mdpi.com/2227-7390/11/1/186>
6. Julio Barzola-Monteses, Monica Mite, Mayken Espinoza, Juan Gómez-Romero, Waldo Fajardo / Time Series Analysis for Predicting Hydroelectric Power Production: The Ecuador Case, URL: https://www.researchgate.net/publication/337404958_Time_Series_Analysis_for_Predicting_Hydroelectric_Power_Production_The_Ecuador_Case
7. Serkan Kiranyaz / 1D convolutional neural networks and applications: A survey, URL: <https://www.sciencedirect.com/science/article/pii/S0888327020307846>
8. Yan Liu / A DLSTM-Network-Based Approach for Mechanical Remaining Useful Life Prediction, URL: <https://www.mdpi.com/1424-8220/22/15/5680>

9. Zengchen Yu, Syed Umar Amin, Musaed Alhussein, Zhihan Lyu /Research on Disease Prediction Based on Improved DeepFM and IoMT, URL: https://www.researchgate.net/publication/349651617_Research_on_Disease_Prediction_Based_on_Improved_DeepFM_and_IoMT
10. Згорткова нейронна мережа – просте пояснення CNN та її застосування, URL: <https://evergreens.com.ua/ua/articles/cnn.html>
11. Деніел Нельсон / Що таке RNN і LSTM у Deep Learning?, URL: <https://www.unite.ai/uk/%D1%89%D0%BE-%D1%82%D0%B0%D0%BA%D0%B5-rnns-%D1%96-lstms-%D1%83-%D0%B3%D0%BB%D0%B8%D0%B1%D0%BE%D0%BA%D0%BE%D0%BC%D1%83-%D0%BD%D0%B0%D0%B2%D1%87%D0%B0%D0%BD%D0%BD%D1%96/>
12. Eniola Alese / The curious case of the vanishing & exploding gradient, URL: <https://medium.com/learn-love-ai/the-curious-case-of-the-vanishing-exploding-gradient-bf58ec6822eb>
13. Ryan T.T.J. / LSTMs Explained: A Complete, Technically Accurate, Conceptual Guide with Keras, URL: <https://medium.com/analytics-vidhya/lstms-explained-a-complete-technically-accurate-conceptual-guide-with-keras-2a650327e8f2>
14. Marius Constantin-Popescu, Valentina Emilia Balas, Liliana Perescu-Popescu, Nikos E Mastorakis / Multilayer perceptron and neural networks, URL: https://www.researchgate.net/publication/228340819_Multilayer_perceptron_and_neural_networks
15. Nahian Ahmed, M. Nazum Islam, Ahmad Saraf Tuba, M.R.C. Mahdy, Mohammad Sujauddin / Solving visual pollution with deep learning: A new nexus in environmental management, URL: https://www.nahianahmed.com/papers/visual_pollution.pdf
16. Mohammad AlElaiwi, Mugahed A. Al-antari, Hafiz Farooq Ahmad / VPP: Visual Pollution Prediction Framework Based on a Deep Active Learning Approach Using Public Road Images, URL: <https://www.mdpi.com/2227-7390/11/1/186>

17. Oracle Help Center / Lead and Lag, URL: https://docs.oracle.com/cd/E66143_01/doc.850/e77654/c_staffing_lead_lag.htm
18. Xueying Zhan, Qingzhong Wang, Kuan-Hao Huang, Haoyi Xiong, Dejing Dou, Antoni B. Chan / A Comparative Survey of Deep Active Learning, URL: <https://arxiv.org/pdf/2203.13450.pdf>
19. Mean Absolute Error ~ MAE [Machine Learning(ML)], 2018, URL: https://medium.com/@20_80_/mean-absolute-error-mae-machine-learning-ml-b9b4afc63077
20. Root Mean Squared Error (What is RMSE?), URL: <https://c3.ai/glossary/data-science/root-mean-square-error-rmse/>
21. Shinichi Mizomaki / Deep Active Learning from the Perspective of Active Learning, URL: https://link.springer.com/chapter/10.1007/978-981-10-5660-4_5
22. FengXiang He, Dacheng Tao / Recent Advances In Deep Learning Theory, URL: <https://arxiv.org/abs/2012.10931>
23. Li Fan, Jiancheng Zou / A Novel Road Crack Detection Technology Based on Deep Dictionary Learning and Encoding Networks, URL: <https://www.mdpi.com/2076-3417/13/22/12299>
24. Yutian Jiang, Haotian Yan, Yiru Zhang, Keqiang Wu, Ruiyuan Liu, Ciyun Lin / RDD-YOLOv5: Road Defect Detection Algorithm with Self-Attention Based on Unmanned Aerial Vehicle Inspection, URL: <https://www.mdpi.com/1424-8220/23/19/8241>
25. Jacob Gildenblat / Overview of Active Learning for Deep Learning, URL: <https://jacobgil.github.io/deeplearning/activelearning>
26. Timnit Gebru / Datasheets for Datasets, URL: <https://dl.acm.org/doi/fullHtml/10.1145/3458723>
27. Dmitry Duplyakin, Jed Brown, Robert Ricci / Active Learning in Performance Analysis, URL: https://www.researchgate.net/publication/311531697_Active_Learning_in_Performance_Analysis

28. Md.Sakib Bin Alam, Maruf Hassan / Deep Learning Modelling Techniques: Current Progress, Applications, Advantages, And Challenges, URL: <https://link.springer.com/article/10.1007/s10462-023-10466-8>
29. Jannik Kossen, Sebastian Farquhar, Yarin Gal, Tom Rainforth / Active Testing: Sample-Efficient Model Evaluation, URL: <https://arxiv.org/abs/2103.05331>
30. Model Evaluation, URL: <https://domino.ai/data-science-dictionary/model-evaluation>
31. Machine Learning Model Evaluation, URL: <https://www.geeksforgeeks.org/machine-learning-model-evaluation/>
32. Shir Chorev / How to Test ML Models, URL: <https://deepchecks.com/how-to-test-machine-learning-models/>
33. Jannik Kossen, Sebastian Farquhar, Yarin Gal, Tom Rainforth / Active Testing: Sample-Efficient Model Evaluation, URL: <https://proceedings.mlr.press/v139/kossen21a/kossen21a.pdf>
34. Simrat Bains, Jaspreet Singh Dhani, Tirth Patel, Jaskaran Singh / An Empirical Study of Supervised and Active Learning Methodologies for Classifying Research Papers, URL: <https://osf.io/2t53f/download>
35. Jongseok Lee, Matthias Humt, Jianxiang Feng, Rudolph Triebel / Estimating Model Uncertainty of Neural Networks in Sparse Information Form, URL: https://www.researchgate.net/publication/343152305_Estimating_Model_Uncertainty_of_Neural_Networks_in_Sparse_Information_Form
36. Електронний ресурс Python, URL: <https://python.org/>
37. Brian Gough / An Introduction to Python, URL: <http://atk.fam.free.fr/fichiers/stage/Python/JF/site/pytut.pdf>
38. Електронний ресурс бібліотеки scikit-learn: <https://scikit-learn.org/stable/>
39. Електронний ресурс GitHub, URL: <https://github.com/>
40. Електронний ресурс Google Colab, ULR: <https://colab.research.google.com/>

ДОДАТКИ

Додаток А

Програмний код реалізації методу прогнозування забруднення дороги на основі підходу глибокого активного навчання

```
# Імпортуємо усі необхідні бібліотеки

import os
import requests
import numpy as np
import tensorflow as tf
import LSTM, Dense
from zipfile import ZipFile
from io import BytesIO
from tensorflow.keras import layers, models
from sklearn.preprocessing import MinMaxScaler
from sklearn.utils import shuffle
from keras.models import Sequential
from keras.layers import Conv1D
from keras.preprocessing.image import ImageDataGenerator

# Підхід до збільшення розмірності вхідних даних
# Завантаження zip файлу з GitHub
url = 'https://github.com/dsmolienko/tfn/raw/main/data.zip' # Замініть на
свої дані
response = requests.get(url)
with ZipFile(BytesIO(response.content), 'r') as zip_ref:
    zip_ref.extractall('your_dataset_directory')

# Завантаження та підготовка даних
train_dir = 'your_dataset_directory/train'
val_dir = 'your_dataset_directory/val'
test_dir = 'your_dataset_directory/test'

# Створюємо генератори
train_datagen = ImageDataGenerator(rescale=1./255,
                                   rotation_range=15,
                                   width_shift_range=0.1,
                                   height_shift_range=0.1,
                                   shear_range=0.1,
                                   zoom_range=0.1,
                                   horizontal_flip=True,
                                   fill_mode='nearest')

val_datagen = ImageDataGenerator(rescale=1./255,
```

```

rotation_range=15,
width_shift_range=0.1,
height_shift_range=0.1,
shear_range=0.1,
zoom_range=0.1,
horizontal_flip=True,
fill_mode='nearest')

test_datagen = ImageDataGenerator(rescale=1./255,
rotation_range=15,
width_shift_range=0.1,
height_shift_range=0.1,
shear_range=0.1,
zoom_range=0.1,
horizontal_flip=True,
fill_mode='nearest')

# Завантажити дані з папок
X_train = train_datagen.flow_from_directory(train_dir)
X_val = val_datagen.flow_from_directory(val_dir)
X_test = test_datagen.flow_from_directory(test_dir)

# Отримуємо дані для навчання
train_generator = train_datagen.flow_from_directory(train_dir)
# Отримуємо дані для валідації
val_generator = val_datagen.flow_from_directory(val_dir)
# Отримуємо дані для тесту
test_generator = test_datagen.flow_from_directory(test_dir)

# Перемішати дані
X_train = shuffle(train_generator)
X_val = shuffle(val_generator)

# Перетворити у вектори
X_train = X_train.reshape((-1, 128*128))
X_val = X_val.reshape((-1, 128*128))
X_test = X_test.reshape((-1, 128*128))

# Перевірити форми векторів
print("X_train shape:", X_train.shape)
print("X_val shape:", X_val.shape)
print("X_test shape:", X_test.shape)

# Визначимо розмір лагу (в кількості відліків)
lag_size = 3

# Створимо лаги для X_train
X_train_lags = []

```

```

for i in range(lag_size):
    X_train_lags.append(X_train[:-i])
X_train_lags = np.hstack(X_train_lags)

# Те саме для X_val
X_val_lags = []
for i in range(lag_size):
    X_val_lags.append(X_val[:-i])
X_val_lags = np.hstack(X_val_lags)

# І для X_test
X_test_lags = []
for i in range(lag_size):
    X_test_lags.append(X_test[:-i])
X_test_lags = np.hstack(X_test_lags)

print("X_train_lags shape:", X_train_lags.shape)
print("X_val_lags shape:", X_val_lags.shape)
print("X_test_lags shape:", X_test_lags.shape)

# Створюємо модель
model = Sequential()

# Додаємо 1D згортковий шар
model.add(Conv1D(filters=32, kernel_size=5, activation='relu',
input_shape=(n_steps, n_features)))

# Компілюємо модель
model.compile(loss='mse', optimizer='adam')

# Перетворюємо дані
X_train_cnn = model.predict(X_train)
X_val_cnn = model.predict(X_val)
X_test_cnn = model.predict(X_test)

print("X_train_cnn shape:", X_train_cnn.shape)
print("X_val_cnn shape:", X_val_cnn.shape)
print("X_test_cnn shape:", X_test_cnn.shape)

# Перетворюємо вектори лагів
X_train_lags_cnn = model.predict(X_train_lags)
X_val_lags_cnn = model.predict(X_val_lags)
X_test_lags_cnn = model.predict(X_test_lags)

print("X_train_lags_cnn shape:", X_train_lags_cnn.shape)
print("X_val_lags_cnn shape:", X_val_lags_cnn.shape)
print("X_test_lags_cnn shape:", X_test_lags_cnn.shape)

```

```

# Конкатенація для навчальних даних
X_train_final = np.concatenate((X_train_cnn, X_train_lags_cnn), axis=1)

# Конкатенація для валідаційних даних
X_val_final = np.concatenate((X_val_cnn, X_val_lags_cnn), axis=1)

# Конкатенація для тестових даних
X_test_final = np.concatenate((X_test_cnn, X_test_lags_cnn), axis=1)

print("X_train_final shape:", X_train_final.shape)
print("X_val_final shape:", X_val_final.shape)
print("X_test_final shape:", X_test_final.shape)

# Створюємо нейромережеву модель визначення рівня забруднення дороги на
зображенні
model = Sequential()
model.evaluate(X_train_final)

# CNN частина
model.add(Conv1D(32, 3, activation='relu', input_shape=(n_steps,
n_features)))
model.add(MaxPooling1D(pool_size=2))

# LSTM частина
model.add(LSTM(64))

# Повнозв'язний шар
model.add(Dense(1, activation='sigmoid'))

# Компіляція
model.compile(loss='binary_crossentropy',
              optimizer='adam',
              metrics=['accuracy'])

# Навчання
model.fit(X_train, y_train,
         epochs=100,
         validation_data=(X_val, y_val))

# Оцінка на тесті
score = model.evaluate(X_test, y_test, verbose=0)
print('Test loss:', score[0])
print('Test accuracy:', score[1])

# Нейромережева модель для прогнозування забруднення доріг на основі підходу
глибокого активного навчання
# Завантажуємо послідовність зображень як часовий ряд
images = np.load(train_datagen)

```

```
# Витягуємо ознаки з зображень за допомогою CNN
perc_model = model #попередньо навчена CNN для екстракції ознак
X_current = perc_model.predict(images)

# Розбиваємо послідовність на вхід і вихід
X_train, y_train = X[:-1], X[1:]

# Створюємо модель
model = Sequential()
model.add(LSTM(32, input_shape=(X_train.shape[1], X_train.shape[2])))
model.add(Dense(1, activation='linear'))

# Навчаємо модель
model.compile(loss='mse', optimizer='adam')
model.fit(X_train, y_train, epochs=100)

# Робимо прогноз на майбутнє
X_future = X_current
y_pred = model.predict(X_future)

print(f"Згідно з поставленою часовою варіативністю зображень, забрудненість
на дорогах наступний раз зміниться на: {y_pred:.2f}%")
```

Додаток Б

Презентаційний матеріал

КВАЛІФІКАЦІЙНА РОБОТА МАГІСТРА

МЕТОД ПРОГНОЗУВАННЯ ЗАБРУДНЕННЯ ДОРІГ НА ОСНОВІ ПІДХОДУ ГЛИБОКОГО АКТИВНОГО НАВЧАННЯ

Виконав:

студент 2 курсу, група КНМ-22-1

СМОЛІЄНКО Данило Валентинович

Керівник:

к.п.н., доцент кафедри КН

ПЕТРОВСЬКИЙ Сергій Степанович

МЕТОД ПРОГНОЗУВАННЯ ЗАБРУДНЕННЯ ДОРІГ
НА ОСНОВІ ПІДХОДУ ГЛИБОКОГО АКТИВНОГО НАВЧАННЯ

МЕТА РОБОТИ ТА ЗАДАЧІ

Мета кваліфікаційної роботи магістра - розробка методу прогнозування забруднення доріг на основі підходу глибокого активного навчання з використанням зображень.

Для досягнення поставленої мети потрібно було виконати наступні завдання:

- Розробити метод прогнозування забруднення доріг на основі підходу глибокого активного навчання.
- Зробити аналіз моделей та методів прогнозування забруднення доріг.
- Провести експерименти та проаналізувати ефективність.

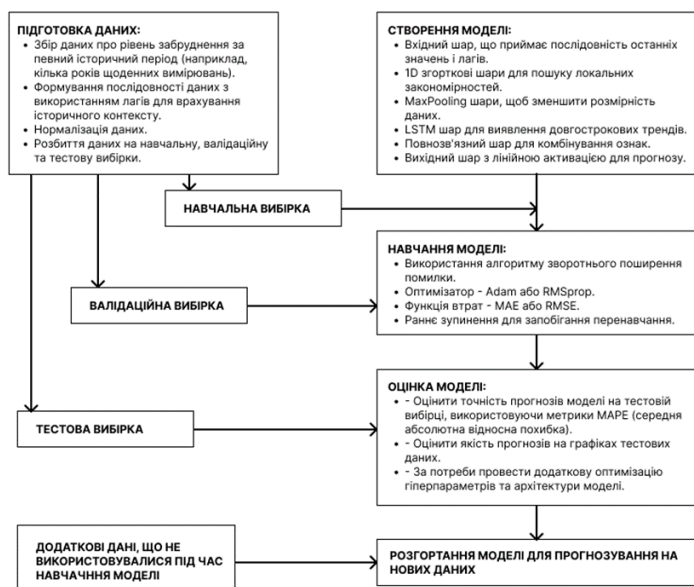
МЕТОД ПРОГНОЗУВАННЯ ЗАБРУДНЕННЯ ДОРІГ НА ОСНОВІ ПІДХОДУ ГЛИБОКОГО АКТИВНОГО НАВЧАННЯ

СХЕМА КРОКІВ РЕАЛІЗАЦІЇ МЕТОДУ ПРОГНОЗУВАННЯ ЗАБРУДНЕННЯ ДОРІГ НА ОСНОВІ ПІДХОДУ ГЛИБОКОГО АКТИВНОГО НАВЧАННЯ



МЕТОД ПРОГНОЗУВАННЯ ЗАБРУДНЕННЯ ДОРІГ НА ОСНОВІ ПІДХОДУ ГЛИБОКОГО АКТИВНОГО НАВЧАННЯ

СХЕМА ЕТАПІВ МОДЕЛІ НАВЧАННЯ ПРОГНОЗУВАННЯ ЗАБРУДНЕННЯ ДОРІГ



МЕТОД ПРОГНОЗУВАННЯ ЗАБРУДНЕННЯ ДОРІГ
НА ОСНОВІ ПІДХОДУ ГЛИБОКОГО АКТИВНОГО НАВЧАННЯ

ПІДХІД ДО ЗБІЛЬШЕННЯ РОЗМІРНОСТІ ДАНИХ



МЕТОД ПРОГНОЗУВАННЯ
ЗАБРУДНЕННЯ ДОРІГ
НА ОСНОВІ ПІДХОДУ
ГЛИБОКОГО АКТИВНОГО
НАВЧАННЯ


**СХЕМА ЕТАПІВ МОДЕЛІ
НАВЧАННЯ ВИЗНАЧЕННЯ
РІВНЯ ЗАБРУДНЕННЯ ДОРІГ**



МЕТОД ПРОГНОЗУВАННЯ ЗАБРУДНЕННЯ ДОРІГ НА ОСНОВІ ПІДХОДУ ГЛИБОКОГО АКТИВНОГО НАВЧАННЯ

ДОСЛІДЖЕННЯ ЕФЕКТИВНОСТІ МОДЕЛІ ДЛЯ ВИЗНАЧЕННЯ РІВНЯ ЗАБРУДНЕНOSTІ


Дослідження показали, що збільшення кількості епох навчання для пошуку рівня забрудненості дороги з зображення, явно підвищує якість такого навчання. До прикладу - коли протягом періоду дослідження було проаналізовано навчання при 10 ітераціях, точність прогнозу для тестової та валідаційної вибірок становила 16,27% та 15,64%, але коли було проаналізовано 700 епох, точність прогнозу зросла до 98,42% та 97,95% відповідно.



МЕТОД ПРОГНОЗУВАННЯ ЗАБРУДНЕННЯ ДОРІГ НА ОСНОВІ ПІДХОДУ ГЛИБОКОГО АКТИВНОГО НАВЧАННЯ

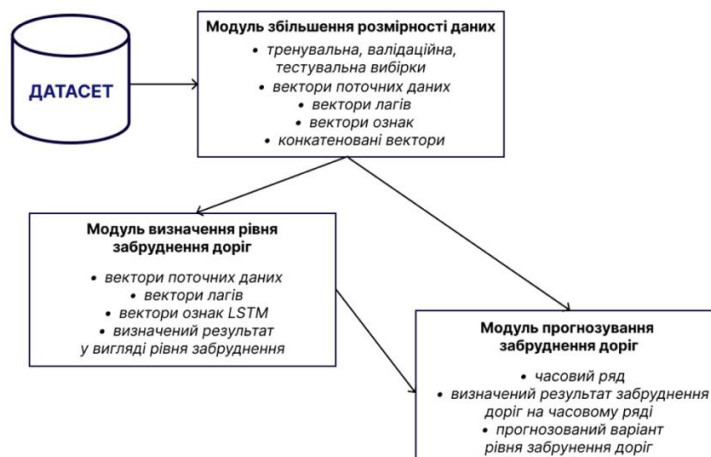
ДОСЛІДЖЕННЯ ЕФЕКТИВНОСТІ МОДЕЛІ ДЛЯ ВИЗНАЧЕННЯ РІВНЯ ЗАБРУДНЕНOSTІ

Дослідження показали, що збільшення кількості періодів навчання (епох), через які проходять дані, відповідно підвищує точність визначення рівня забруднення доріг. Наприклад, коли протягом періоду дослідження було проаналізовано 10 зразків відповідних параметрів, точність прогнозу становила 1,24%, але коли було проаналізовано 700 зразків, точність прогнозу зросла до 97,84%.



МЕТОД ПРОГНОЗУВАННЯ ЗАБРУДНЕННЯ ДОРІГ НА ОСНОВІ ПІДХОДУ ГЛИБОКОГО АКТИВНОГО НАВЧАННЯ

СТРУКТУРА КОМПОНЕНТІВ ІНФОРМАЦІЙНОЇ СИСТЕМИ РОЗРОБЛЕНОГО МЕТОДУ



МЕТОД ПРОГНОЗУВАННЯ ЗАБРУДНЕННЯ ДОРІГ НА ОСНОВІ ПІДХОДУ ГЛИБОКОГО АКТИВНОГО НАВЧАННЯ

ПОЛОЖЕННЯ НОВИЗНИ ТА ІННОВАЦІЇ

Запропоновано метод прогнозування забруднення доріг на основі підходу глибокого активного навчання. При розробці методу були застосовані глибокі нейронні мережі для підходу активного навчання, для аналізу та прогнозування забруднення доріг. Було адаптовано нейронну мережу до предметної області, а саме до розпізнавання забруднення доріг шляхом зміни гіперпараметрів, що в подальшому дозволяє прогнозувати рівень такого забруднення з зображень.

Вдосконалено нейромережеві моделі для визначення рівня забрудненості на зображенні та для прогнозування рівня забруднення. Було використано поєднання кращих особливостей декількох нейромережевих моделей – CNN, LSTM, повнозв'язних шарів.

Вдосконалено підхід до обробки зображень за рахунок збільшення розмірності вхідних даних, що можливо завдяки перетворенню невеликої кількості зображень у часовий ряд.



МЕТОД ПРОГНОЗУВАННЯ ЗАБРУДНЕННЯ ДОРІГ
НА ОСНОВІ ПІДХОДУ ГЛИБОКОГО АКТИВНОГО НАВЧАННЯ

ЗАГАЛЬНІ ВИСНОВКИ

Кваліфікаційна робота магістра розв'язує наукову задачу прогнозування забруднення доріг на основі підходу глибокого активного навчання, для чого було розроблено підхід до визначення рівня забрудненості дороги з використанням зображень та використано нейромережеву модель для прогнозування рівня забруднення дороги на основі вхідних даних у вигляді часового ряду із зображень, що були зроблені в певний період спостереження. Для реалізації такого методу було розроблено відповідні програмні засоби.

За результатом виконання роботи були поставлені та вирішені **наступні завдання**:

- Розроблено метод прогнозування забруднення доріг на основі підходу глибокого активного навчання.
- Проведено аналіз моделей та методів прогнозування забруднення доріг.
- Проведено експерименти та проаналізовано ефективність методу.

УДК 004

Смолієнко Д.В., Петровський С.С.

Хмельницький національний університет

МЕТОД ПРОГНОЗУВАННЯ ЗАБРУДНЕННЯ ГРОМАДСЬКИХ ДОРІГ НА ОСНОВІ ПІДХОДУ ГЛИБОКОГО АКТИВНОГО НАВЧАННЯ

Запропоновано метод прогнозування рівня забруднення громадських доріг на основі підходу глибокого активного навчання з використанням зображень. Головна мета - поліпшити контроль та управління забрудненням доріг, забезпечуючи швидке та точне прогнозування рівня забруднення на основі вхідних зображень за допомогою методу, що використовує нейромережі глибокого навчання, зокрема згорткові нейромережі (CNN). Це дозволить вживатичасні заходи для зменшення забруднення на дорогах.

A method for predicting the level of pollution on public roads is proposed based on a deep active learning approach using images. The main goal is to improve the control and management of road pollution by providing fast and accurate forecasting of pollution levels based on input images using a method that utilizes deep learning neural networks, particularly Convolutional Neural Networks (CNN). This will enable timely measures to reduce road pollution.

Забруднення доріг є серйозною проблемою в Україні, яка погіршує стан інфраструктури, повітря та здоров'я населення. Незважаючи на спроби вирішити цю проблему, рівень забруднення доріг продовжує зростати з кожним роком.

Глибоке активне навчання, що використовує згорткові нейронні мережі, може автоматизувати оцінку якості доріг в реальному часі. Аналіз зображень з камер спостереження дозволить збирати дані про рівень та типи забруднення. Ця інформація допоможе розробити комплексний підхід до моніторингу та покращення стану доріг в Україні.

Існуючі методи прогнозування забруднення доріг мають свої переваги і недоліки.

Згорткові нейронні мережі (CNN) ефективно розпізнають візуальні ознаки, автоматизують процес і масштабуються. Проте вони потребують багато даних, чутливі до шуму і складні в інтеграції.

Рекурентні нейронні мережі (RNN) моделюють послідовності і часову динаміку. Однак у них є проблеми із зникненням градієнта, довгостроковими залежностями і обчислювальною складністю.

Ансамблі моделей підвищують точність і стабільність за рахунок поєднання підходів. Проте вони складніші у навчанні, інтерпретації і потребують більше ресурсів.

Незважаючи на переваги, кожен метод має обмеження. Тому пропонується розглянути новий підхід, який дозволить подолати недоліки існуючих методів для ефективного та точного прогнозування забруднення доріг.

Метод TFN

Розглянемо метод Temporal Fusion Network (TFN) для прогнозування забруднення доріг.

TFN поєднує переваги згорткових нейронних мереж та рекурентних нейронних мереж:

- Згорткові шари аналізують просторові особливості на зображеннях доріг.
- RNN-шар (LSTM) моделює часову динаміку змін забруднення.

Така архітектура дозволяє враховувати як візуальні, так і темпоральні закономірності.

Порівняно з іншими методами, TFN має такі переваги:

- Автоматичний підбір оптимальних параметрів моделі.
- Врахування динаміки змін рівня забруднення.
- Гнучкість та адаптивність до різних умов.
- Потенціал для підвищення точності прогнозування.

Загалом, TFN є перспективним підходом для прогнозування забруднення доріг на основі аналізу зображень з урахуванням часової динаміки.

Архітектура TFN (таблиця 1) складається з наступних основних компонентів:

1. Згорткові шари для аналізу просторових особливостей зображень:
 - Розмір ядра: 3x3 або 5x5
 - Кількість фільтрів: 16-32
 - Крок зсуву: 1 піксель
 - Активація: ReLU
2. RNN шар (LSTM) для моделювання часової динаміки:
 - Кількість LSTM одиниць: 32-64
 - Збереження коротко- та довгострокової пам'яті
3. Об'єднання особливостей згорткових і RNN шарів
4. Повнозв'язний шар для аналізу інтегрованих особливостей:
 - Кількість нейронів: 64-128
 - Активація: ReLU
5. Вихідний шар з 1 нейроном для прогнозування рівня забруднення:
 - Активація: лінійна або сигмоїдна

Загалом, TFN поєднує можливості CNN та RNN для аналізу просторових і часових закономірностей в даних про забруднення доріг. Кількість шарів і параметри можуть варіюватися в залежності від задачі.

Таблиця 1 – Архітектура TFN

	Шар	Опис
1.	Вхідний	Зображення дороги
2.	Згорткові	Виявлення просторових особливостей
3.	Пулінгові	Зменшення розмірності виходу згорткових шарів
4.	LSTM-рекурентний	Аналіз темпоральних залежностей та моделювання динаміки змін
5.	Повноз'язані	Остаточне прогнозування рівня забруднення доріг
6.	Вихідний	Прогнозована забрудненість доріг

Навчання моделі

Навчання моделі за допомогою методу TFN включатиме мінімізацію функції втрати за допомогою оптимізаційного алгоритму, такого як стохастичний градієнтний спуск. Формула для оновлення параметрів моделі буде залежати від обраного алгоритму оптимізації.

Загальна формула оновлення параметрів моделі в процесі навчання може бути записана наступним чином:

$$\theta(t+1) = \theta(t) - \alpha * \nabla L,$$

де: $\theta(t)$ – вектор параметрів моделі на кроці навчання t , α – швидкість навчання (learning rate), ∇L – градієнт функції втрати L відносно параметрів моделі.

Конкретна формула для обчислення градієнту ∇L залежить від використаної функції втрати та архітектури моделі. В даному випадку, згідно з гіпотетичним методом TFN, формула для обчислення градієнту буде включати зворотне поширення помилки (backpropagation) через згорткові та LSTM-рекурентні шари моделі.

За допомогою цієї формули, параметри моделі будуть оновлюватись на кожному кроці навчання, щоб мінімізувати значення функції втрати і покращити точність прогнозів моделі.

Експериментальні результати

Експериментальне випробування методу було здійснено за допомогою мови програмування Python, що має багату екосистему бібліотек для потрібних завдань та зручний синтаксис.

Середовище розробки Google Colab стало найкращим вибором через інтерактивність роботи, широкий вибір вбудованих бібліотек Python та можливість використання обчислювальних ресурсів. Його інтерактивність проявляється у системі блокнотів для написання коду, що дозволяє виконувати код крок за кроком і бачити результати його дії. Google Colab підтримує багато популярних бібліотек та фреймворків для машинного навчання, такі як TensorFlow, PyTorch, Keras, що і застосовуються у експерименті. Також це середовище завжди готове до використання обчислювального ресурсу - Google Colab надає доступ до віртуальних машин з GPU та TPU, що дозволяє вам виконувати обчислення для навчання великих моделей швидше, ніж на звичайних CPU.

Обраний датасет з джерела Kaggle містить сотні різноманітних зображень із забрудненими та чистими дорогами, що і надає можливість робити подальші експерименти.

Експериментальні результати виявилися успішними, так як втрати при тренуванні моделі були низькими, а найвища акуратність лише при 10 ітераціях сягнула 96.43%, а час виконання сягнув лише 21 секунд.

Якщо ж збільшувати кількість ітерацій, втрати будуть зменшуватися, а акуратність відповідно збільшуватись, і вже при 20 ітераціях матимемо 100% акуратність і час виконання 47 секунд.

Висновки

Результати дослідження показали, що TFN може забезпечувати точні прогнози рівня забруднення доріг, враховуючи просторові залежності в даних. Метод виявився ефективним у виявленні та аналізі просторових ознак на зображеннях доріг, а також у моделюванні та прогнозуванні темпоральних залежностей.

Використання автоматичного вибору оптимальних параметрів методу дозволяє досягти кращих результатів прогнозування та адаптуватися до різних умов та типів даних. Метод TFN відрізняється від інших готових методів завдяки поєднанню згорткових шарів та LSTM-рекурентного шару. Це дозволяє пришвидшити навчання машини та отримувати кращі результати.

Розроблений метод TFN є перспективним інструментом для прогнозування забруднення громадських доріг на основі аналізу зображень і моделювання динаміки змін. Подальші дослідження можуть включати оптимізацію архітектури TFN, вдосконалення функцій втрати та дослідження його ефективності на реальних даних.

Перелік посилань

1. Екологічний паспорт області [Електронний ресурс] – Хмельницький, ХОВА, 2023 – Режим доступу: https://www.adm-km.gov.ua/?page_id=7157
2. VPP: Visual Pollution Prediction Framework Based on a Deep Active Learning Approach Using Public Road Images [Електронний ресурс] – 2022 – <https://www.mdpi.com/2227-7390/11/1/186>
3. Згорткова нейронна мережа – просте пояснення CNN та її застосування [Електронний ресурс] – Україна, 2019 – Режим доступу: <https://evergreens.com.ua/ua/articles/cnn.html>
4. "Deep Learning Techniques for Natural Language Processing" [Електронний ресурс]. - Режим доступу: <https://www.sciencedirect.com/science/article/pii/S2666651721000127>
5. "Deep Learning Methods in Recommender Systems" [Електронний ресурс]. - Режим доступу: <https://www.sciencedirect.com/science/article/pii/S110866519300845>

Довідка: ВХНУ ТН 21/11/23

Видання: Вісник Хмельницького національного університету. Технічні науки

Категорія фаховості видання: фахове видання України, у якому можуть публікуватися результати дисертаційних робіт на здобуття наукових ступенів доктора наук, кандидата наук та ступеня доктора філософії, категорії «Б» філософії, категорії «Б» (наказ МОН №1643 від 28.12.2019, наказ МОН №409 від 17.03.2020).

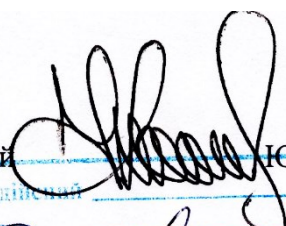
Напрямок – технічні науки за спеціальностями – 101, 121, 122, 123, 124, 125, 141, 151, 161, 172, 181, 182 (28.12.2019), спеціальності – 131, 132, 133 (17.03.2020)

Назва статті: МЕТОД ПРОГНОЗУВАННЯ ЗАБРУДНЕННЯ ДОРІГ НА ОСНОВІ ПІДХОДУ ГЛИБОКОГО АКТИВНОГО НАВЧАННЯ

Автори: Смолієнко Данило, Петровський Сергій (Хмельницький національний університет)

Номер, у який прийнято статтю: №6 до друку рекомендовано буде до 25 грудня 2023 року.

21.11.2023

Начальник відділу інтелектуальної власності та трансферу технологій  Ю.В.Кравчик



УДК 004.4

Хмельницький національний університет

СМОЛІЄНКО Данило Валентинович

e-mail: dsmoliienko@gmail.com

ПЕТРОВСЬКИЙ Сергій Степанович

ORCID ID: 0000-0002-0590-0484

e-mail: petrovskijs69@gmail.com

МЕТОД ПРОГНОЗУВАННЯ ЗАБРУДНЕННЯ ДОРІГ НА ОСНОВІ ПІДХОДУ ГЛИБОКОГО АКТИВНОГО НАВЧАННЯ

У статті запропоновано метод прогнозування забруднення доріг на основі підходу глибокого активного навчання. Метод дозволяє моделювати майбутню динаміку зміни рівня забрудненості дорожнього покриття в часі на відміну від існуючих підходів, орієнтованих на аналіз поточного стану. Основою методу є застосування рекурентної нейронної мережі LSTM та техніка збільшення розмірності даних. Головна мета дослідження – розробити метод прогнозування забруднення доріг на основі підходу глибокого активного навчання та дослідити його ефективність. Це дозволить вживати вчасні заходи для зменшення забруднення та поліпшення якості інфраструктури доріг.

Ключові слова: забруднення доріг, глибоке активне навчання, прогнозування, нейромережі, транспорт.

SMOLIENKO Danylo, PETROVSKYI Serhii.

Khmelnitskyi National University

PREDICTION METHOD FOR PUBLIC ROAD POLLUTION BASED ON DEEP ACTIVE LEARNING APPROACH USING IMAGE ANALYSIS

The study proposes a method of predicting road pollution based on the approach of deep active learning. The proposed method allows modeling the future dynamics of changes in the level of road surface pollution over time, in contrast to existing approaches, which are mainly focused on the analysis of the current state in real time. The main goal of the work is to improve road pollution control and management systems by providing accurate forecasting of the level of pollution based on input data. This will allow timely measures to reduce pollution and improve the quality of road infrastructure.

The basis of the proposed method is the use of a recurrent LSTM neural network. In addition, the technique of increasing the dimensionality of the data by introducing lags (time-shifted variables) is used to more effectively take into account historical dependencies when building a predictive model.

In addition, the work improved the procedure for measuring the current level of pollution based on a combination of neural networks CNN (for analyzing road surface images) and LSTM (for modeling the temporal dynamics of changes).

The proposed comprehensive approach makes it possible to determine the current state and predict the future level of road infrastructure pollution with high accuracy. The developed method can be applied in practice for planning cleaning works, optimizing road maintenance schedules and other purposes in the field of transport infrastructure management.

The obtained results allow us to conclude that lengthening the process of learning the model, i.e. increasing the number of epochs through multiple analysis and adjusting the weight coefficients of the neural network, has a positive effect on the accuracy of predictive calculations of the level of pollution for a given future period. Thus, it can be argued that the proposed approach is effective for solving the given task.

The research also confirmed the effectiveness of the proposed method based on deep active learning for solving the task of predicting road pollution.

Keywords: road pollution, deep active learning, forecasting, neural networks, transport.

Вступ

Забрудненість доріг є актуальною проблемою сучасних міст [1]. Зростання кількості транспорту та обсягів відходів призводить до погіршення стану дорожньої інфраструктури. Це негативно позначається на економіці, екології та здоров'ї населення. Тому питання контролю та прогнозування рівня забрудненості є вкрай важливим.

Існуючі підходи до вирішення проблеми контролю та прогнозування забрудненості доріг мають ряд суттєвих недоліків. Зокрема, традиційні ручні методи, що базуються на безпосередньому спостереженні та зборі даних людьми, є досить трудомісткими та потребують значних людських і часових ресурсів.

Щодо автоматизованих рішень, які ґрунтуються на класичних алгоритмах машинного навчання, то вони часто не забезпечують необхідної точності прогнозних моделей внаслідок недостатньої здатності до узагальнення та виявлення складних залежностей у даних.

Тому актуальним є розробка інноваційного підходу на основі технологій глибокого активного навчання, який поєднував би високу точність зі швидкістю та автоматизацією процесів аналізу даних і прогнозування. Це дозволить підвищити ефективність систем моніторингу та контролю стану доріг.

Метою даного дослідження є розробка методу прогнозування забруднення доріг на основі підходу глибокого активного навчання та оцінка його ефективності.

Аналіз існуючих рішень

Проблема прогнозування забруднення доріг є актуальною та такою, що вивчається тривалий час. Існуючі теоретичні та практичні напрацювання мають певні обмеження. Зокрема, традиційні математичні моделі не завжди забезпечують необхідну точність через складність формалізації всіх чинників впливу.

Останнім часом активно розвивається напрям глибокого активного навчання [2] як ефективний підхід машинного навчання для прогнозних задач. Він дозволяє будувати точні моделі з мінімальним обсягом даних для навчання. Але наявні розробки цього напрямку для прогнозування забрудненості доріг [3] все ще мають певні обмеження. Зокрема, дослідження показують залежність якості моделей від умов зйомки даних та обмеженість їх застосування для різних регіонів. Крім того, такі моделі потребують великої кількості апаратних ресурсів, що значно збільшує затрати на їх використання.

Також потребує вдосконалення процедура отримання навчальних даних, яка наразі значною мірою залежить від ручної розмітки експертами.

Крім цього, існують різні підходи до моделювання та прогнозування забруднення доріг. Математичні моделі дозволяють формалізувати залежності між параметрами цього процесу у вигляді рівнянь. Зокрема, з використанням моделі часових рядів можна проаналізувати історичні дані та екстраполювати виявлені тенденції у майбутнє. Проте такий підхід не завжди адекватно відображає вплив зовнішніх факторів.

Альтернативою є стохастичне моделювання з урахуванням ймовірнісного характеру деяких змінних. Це дає змогу побудувати розподіли ймовірностей прогнозованого рівня забруднення залежно від реалізації випадкових факторів. Проте потребує значного обсягу статистичних даних для адекватного оцінювання параметрів моделей.

Найпопулярнішими підходами до вирішення поставленої проблеми на сьогодні є підходи до нейронних мереж, які мають багато переваг. Зокрема, детально розглядаються такі методи:

1) згорткові нейронні мережі (CNN) [4]. Вони добре підходять для розпізнавання зображень, можуть виділяти ключові характеристики, як-от краї, контури, текстури. Однак CNN чутливі до зміни орієнтації зображення.

2) рекурентні нейронні мережі (RNN) [5]. Вони враховують історичний контекст та ефективні для моделювання часових рядів. Проте страждають від проблем градієнта.

3) мережі LSTM [6]. Це посилена версія RNN, яка вирішує деякі її недоліки. LSTM містить спеціальні вентиля для кращої обробки даних. Однак LSTM вимагає великих обчислювальних ресурсів.

4) багат шаровий перцептрон (MLP) [7]. Може застосовуватися для класифікації зображень та прогнозування. Проте MLP має проблеми з локальними мінімумами під час навчання.

Для задачі прогнозування забруднення доріг найбільш підходять CNN та LSTM моделі, які поєднують переваги глибокого навчання з обробкою часових рядів даних. Проте потрібно враховувати їх недоліки та можливі удосконалення. Отже, актуальним завданням є розробка універсального та автоматизованого методу саме прогнозування майбутнього рівня забрудненості доріг на основі глибокого активного навчання з врахуванням недоліків попередніх підходів.

Виклад основного матеріалу

Створення методу прогнозування забруднення доріг на основі підходу глибокого активного навчання дозволить створити структуровану та організовану роботу для поведінки з відходами на дорогах. Для роботи такого методу було створено три модулі: модуль прогнозування забруднення дороги, модуль збільшення розмірності вхідних даних, модуль визначення рівня забруднення на дорозі з зображення.

Для прогнозування забруднення доріг розроблено нейромережеву модель на основі поєднання довгої короткочасної пам'яті та згорткової нейронної мережі. Така гібридна архітектура дозволяє враховувати як локальні закономірності за рахунок згортки, так і моделювати довгострокові тенденції з використанням рекурентних шарів.

Побудова моделі включає підготовку наборів даних, формування вхідних векторів з урахуванням історичного контексту, налаштування параметрів згорткових та рекурентних шарів. Навчання моделі здійснюється методом зворотного поширення помилки з подальшою оптимізацією на основі градієнтного спуску. Архітектура має наступний вигляд:

1. **підготовка даних:** збір часового ряду вимірювань рівня забруднення за тривалий період, формування вхідної послідовності з лагами, нормалізація, розподіл на навчальну, валідаційну та тестову вибірки.

2. **створення моделі:** вхідний шар для часового ряду \rightarrow 1D згорткові шари для виділення ознак \rightarrow MaxPooling шари для регуляризації та інваріантності \rightarrow LSTM шар для моделювання залежностей \rightarrow повнозв'язний шар \rightarrow вихідний шар з лінійною активацією.

3. **навчання моделі.** Модель представляється як функція f , що намагається наблизити $y - y = f(x, \theta)$, де: θ – параметри моделі, які підлаштовуються в процесі навчання.

Використовуючи алгоритм зворотного поширення помилки можна отримати оновлення ваг моделі на основі градієнта функції втрат. Після цього за обраним оптимізатором Adam, що об'єднує переваги одразу декількох існуючих методів, відбувається налаштування швидкості навчання для кожного параметра, що прискорює конвергенцію: $\theta' = \theta - \alpha \nabla \theta L(\theta)$,

де: α - швидкість навчання.

Саме навчання в основному полягає у функції втрат $L(\theta)$ середньоквадратичної похибки RMSE, яка є доцільною через свою чутливість до великих похибок і підходить для задач регресії та прогнозування:

$L(\theta) = 1/N \sum (y - f(x; \theta))^2$, де: N - розмір набору даних.

4. **застосування оптимізатора Adam** та методу ранньої зупинки.
5. **підбір гіперпараметрів** на валідаційній вибірці.
6. **оцінка якості** моделі.

Запропонована архітектура демонструє високу ефективність у прогнозуванні зміни рівня забрудненості доріг завдяки поєднанню просторового та часового моделювання даних за рахунок CNN та LSTM відповідно.

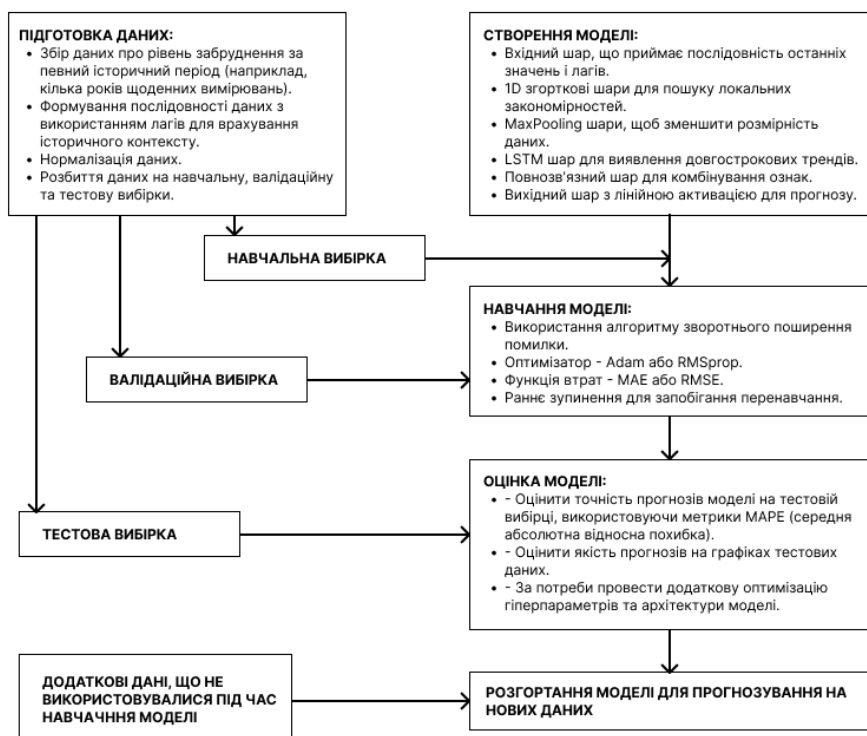


Рис. 1 – Схема нейромережевої моделі прогнозування

Для покращення ефективності прогнозувальної моделі було застосовано метод збільшення розмірності вхідних даних на основі додавання лагів - зміщених у часі значень часового ряду. Це дозволяє врахувати попередню історію та контекст, що підвищує здатність моделі виявляти різноманітні тимчасові закономірності, тренди та сезонності.

Також було використано 1D згорткові шари, які автоматично виділяють найбільш інформативні ознаки з послідовності лагів та поточних даних. Поєднання лагів і згорток надає моделі як глобальний часовий контекст, так і можливість аналізу локальних особливостей, що в комплексі покращує якість прогнозних розрахунків.



Рис. 2 – Комбінування векторів даних для збільшення розмірності

Для визначення поточного рівня забрудненості доріг розроблено комбінований підхід на основі двох моделей глибокого навчання: згорткових та рекурентних нейронних мереж. CNN аналізує зображення та виділяє візуальні ознаки наявності бруду, а LSTM додатково враховує часові закономірності та історичний контекст.

Результати подаються у відносних відсотках забрудненості за шкалою від 0 до 100%. Це значення зручне для подальшого використання, зокрема як вхідний параметр для моделювання динаміки змін рівня забруднення. Запропонована комбінація LSTM та CNN демонструє високу точність оцінки поточного стану дорожнього покриття.



Рис. 3 – Схема нейромережевої моделі визначення рівня забруднення

Запропонований метод прогнозування забруднення доріг на основі глибокого активного навчання має наступні етапи реалізації:

1. Вхідні дані: часовий ряд показника забрудненості + лагові змінні. Здійснюється фільтрація та нормалізація даних.

2. Формування входів моделі.
3. Нормалізація ваг згорткового шару.
4. Навчання нейромережі для прогнозування.
5. Отримання прогнозованого рівня забруднення.
6. Перевірка якості за допомогою функцій. При потребі - зміна гіперпараметрів.
7. Оцінка на тестовій вибірці.

Перевага такого підходу до прогнозування - можливість отримати кількісні значення прогнозованого рівня забруднення для прийняття обґрунтованих рішень щодо очищення доріг.

Експериментальні результати

Для дослідження ефективності методу прогнозування забруднення доріг використано набір даних зі зображеннями однієї дороги в різний час та з різним рівнем забруднення.

Зображення зроблені в місті Хмельницький, Україна, у різний час доби та дні тижня. Загалом датасет налічує 500 зображень, з яких 40% - навчальна вибірка, 40% - валідаційна вибірка, а 20% - тестова.

Переваги такого набору даних:

- різні умови на дорозі: забрудненість, освітлення тощо
- різний час зйомки дозволяє створити єдиний часовий ряд

Це дозволить краще навчити модель прогнозування рівня забруднення на основі зображень та часових характеристик.




Рис. 4 – приклад фото з датасету

Після нормалізації, зображення з набору даних буде виглядати наступним чином:




Рис. 5 – перетворене зображення.

Для оцінки ефективності розробленого методу прогнозування забруднення доріг було проведено дослідження точності прогнозування відносно різної кількості епох (ітерацій) навчання нейромережевої моделі. Суть дослідження полягала у порівнянні точності прогнозів забруднення доріг при різних значеннях кількості навчальних ітерацій моделі. Таке дослідження проводилося за допомогою метрики MAE. Під час експериментів використовувались різні значення кількості епох навчання в діапазоні від 10 до 700.




Рис. 6 – результати дослідження ефективності

Коли протягом періоду дослідження було проаналізовано 10 зразків відповідних параметрів, точність прогнозу становила 1,24%, але коли було проаналізовано 700 зразків, точність прогнозу зросла до 97,84%.

Висновок

Дослідження розв'язує поставлену проблему і пропонує метод прогнозування забруднення доріг на основі підходу глибокого активного навчання. Результати показали, що досліджуваний метод є ефективним засобом для прогнозування, що відкриває можливість у полегшенні управління забрудненням на дорогах за допомогою зображень.

Триваліше навчання моделі (збільшення кількості епох) покращує точність прогнозування, що дозволяє виконувати надточні прогнози для будь-якої з доріг. Зі збільшенням кількості аналізованих зразків вхідних даних точність методу зростає (наприклад, з 1,24% для 10 зразків до 97,84% для 700).

Запропонований метод на основі глибокого навчання ефективно вирішує задачу прогнозування забруднення доріг.

Літературні джерела

1. Екологічний паспорт області - Хмельницький, ХОБА, 2023. URL: https://www.adm-km.gov.ua/?page_id=7157
2. A Comparative Survey of Deep Active Learning. URL: <https://arxiv.org/pdf/2203.13450.pdf>.
3. VPP: Visual Pollution Prediction Framework Based on a Deep Active Learning Approach Using Public Road Images. URL: <https://www.mdpi.com/2227-7390/11/1/186>
4. Згорткова нейронна мережа – просте пояснення CNN та її застосування. URL: <https://evergreens.com.ua/ua/articles/cnn.html>
5. Що таке RNN і LSTM у Deep Learning? URL: <https://www.unite.ai/uk/%D1%89%D0%BE-%D1%82%D0%B0%D0%BA%D0%B5-rnns-%D1%96-lstms-%D1%83-%D0%B3%D0%BB%D0%B8%D0%B1%D0%BE%D0%BA%D0%BE%D0%BC%D1%83-%D0%BD%D0%B0%D0%B2%D1%87%D0%B0%D0%BD%D0%BD%D1%96/>
6. LSTMs Explained: A Complete, Technically Accurate, Conceptual Guide with Keras. URL: <https://medium.com/analytics-vidhya/lstms-explained-a-complete-technically-accurate-conceptual-guide-with-keras-2a650327e8f2>
7. Multilayer perceptron and neural networks. URL: https://www.researchgate.net/publication/228340819_Multilayer_perceptron_and_neural_networks
8. Deep Active Learning from the Perspective of Active Learning Theory. URL: https://link.springer.com/chapter/10.1007/978-981-10-5660-4_5
9. Recent advances in deep learning theory URL: <https://arxiv.org/abs/2012.10931>
10. A Novel Road Crack Detection Technology Based on Deep Dictionary Learning and Encoding Networks. URL: <https://www.mdpi.com/2076-3417/13/22/12299>

References

1. Ekolohichniy pasport oblasti - Khmelnytskyi, KhOVA, 2023. URL: https://www.adm-km.gov.ua/?page_id=7157
2. A Comparative Survey of Deep Active Learning. URL: <https://arxiv.org/pdf/2203.13450.pdf>

3. VPP: Visual Pollution Prediction Framework Based on a Deep Active Learning Approach Using Public Road Images. URL: <https://www.mdpi.com/2227-7390/11/1/186>
4. Zghortkova neironna merezha – proste poiasnennia CNN ta yii zastosuvannia. URL: <https://evergreens.com.ua/ua/articles/cnn.html>
5. Shcho take RNN i LSTM u Deep Learning? URL: <https://www.unite.ai/uk/%D1%89%D0%BE-%D1%82%D0%B0%D0%BA%D0%B5-rnns-%D1%96-lstms-%D1%83-%D0%B3%D0%BB%D0%B8%D0%B1%D0%BE%D0%BA%D0%BE%D0%BC%D1%83-%D0%BD%D0%B0%D0%B2%D1%87%D0%B0%D0%BD%D0%BD%D1%96/>
6. LSTMs Explained: A Complete, Technically Accurate, Conceptual Guide with Keras. URL: <https://medium.com/analytics-vidhya/lstms-explained-a-complete-technically-accurate-conceptual-guide-with-keras-2a650327e8f2>
7. Multilayer perceptron and neural networks. URL: https://www.researchgate.net/publication/228340819_Multilayer_perceptron_and_neural_networks
8. Deep Active Learning from the Perspective of Active Learning Theory. URL: https://link.springer.com/chapter/10.1007/978-981-10-5660-4_5
9. Recent advances in deep learning theory. URL: <https://arxiv.org/abs/2012.10931>
10. A Novel Road Crack Detection Technology Based on Deep Dictionary Learning and Encoding Networks. URL: <https://www.mdpi.com/2076-3417/13/22/12299>

Anti-Plagiarism v-15.257

Максимальне співпадіння з одним документом 0.0%

Словники перевірки: en_US, ru_RU, ua_UA. **Помилки в документах: 9%**

ID: 122060 Назва: КВАЛІФІКАЦІЙНА РОБОТА МАГІСТРА на тему Метод прогнозування забруднення доріг на основі підходу глибокого активного навчання Додано в БД: 2023-12-07 Автора: Д.В. Смолієнко Керівники: С.С. Петровський Консультанти: Опоненти:	Документ		Сумарний збіг по Базі Даних	
	Символи	Лексеми	Символи	Лексеми
	95547	1355	1295 (1%)	23 (2%)

Джерело плагіату

ID	Опис	Наявність плагіату в документі	
		Символи	Лексеми

Ім'я користувача:
Кафедра КН

ID перевірки:
1015980805

Дата перевірки:
07.12.2023 15:35:14 EET

Тип перевірки:
Doc vs Internet + Library

Дата звіту:
07.12.2023 15:38:18 EET

ID користувача:
100005671

Назва документа: КНм-22-1 СМОЛІЄНКО

Кількість сторінок: 77 Кількість слів: 14166 Кількість символів: 108637 Розмір файлу: 1.66 MB ID файлу: 1015660946

8.17% Схожість

Найбільша схожість: 1.04% з Інтернет-джерелом (http://elar.khmnu.edu.ua/jspui/bitstream/123456789/12849/1/2022_%d).

7.78% Джерела з Інтернету

759

Сторінка 79

2.94% Джерела з Бібліотеки

113

Сторінка 84

0% Цитат

Вилучення цитат вимкнено

Вилучення списку бібліографічних посилань вимкнено

0% Вилучень

Немає вилучених джерел

Модифікації

Виявлено модифікації тексту. Детальна інформація доступна в онлайн-звіті.

Замінені символи

4

РІШЕННЯ ЕКСПЕРНОЇ КОМІСІЇ
КАФЕДРИ КОМП'ЮТЕРНИХ НАУК

ПРО ДОПУСК КВАЛІФІКАЦІЙНОЇ РОБОТИ МАГІСТРА ДО ЗАХИСТУ ЗА
РЕЗУЛЬТАТАМИ АНАЛІЗУ ЗВІТУ ПОДІБНОСТІ

Підтверджуємо ознайомлення з результатом звіту подібності щодо роботи, генерованого системою виявлення текстових збігів/ідентичності/схожості:

Назва: Метод прогнозування забруднення доріг на основі підходу глибокого активного навчання

Автор: Смоліснко Данило Валентинович

Спеціальність: 122 – Комп'ютерні науки

Освітня програма: освітньо-професійна

Науковий керівник: к.п.н., доц. Петровський С.С.

Після аналізу звіту подібності зроблено такий висновок:

№	Висновок	Позначка про відповідність
1	Запозичення, виявлені в роботі, є законними і не є плагіатом. Робота приймається до захисту.	відповідає
2	Виявлені запозичення не є плагіатом, розміщені в розділах, які не описують безпосередньо авторське дослідження, але кількість цитат перевищує обсяг, виправданий поставленою метою роботи. Робота приймається до захисту, але має бути відкоригована. Відкоригований варіант має бути поданий на кафедру за 2 дні до захисту, разом із заявою щодо самостійності виконання письмової роботи та ідентичності друкованої та електронної версії роботи	
3	Виявлені запозичення не є плагіатом, але частково розміщені в розділах, які описують безпосередньо авторське дослідження, а кількість цитат перевищує обсяг, виправданий поставленою метою роботи. В зв'язку з цим мета роботи та поставлені завдання не були досягнені. Робота може бути допущена до захисту (наступного року) після того як буде відкоригована та допрацьована і успішно пройде повторну перевірку на академічний плагіат.	
4	Робота містить навмисні текстові спотворення, передбачувані спроби укриття запозичень або інші прояви академічного плагіату. Робота містить фабрикацію або фальсифікацію даних. Робота не допускається до захисту.	

Підтвердження:

Запозичення, виявлені в роботі, є законними і не є плагіатом, оскільки:

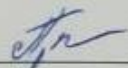
- 1) за програмою Anti-Plagiarism виявлені 0% є фрагментарними – містять поширені конструкції, загальновідомі терміни, скорочення та визначення.
- 2) За програмою UNICHECK виявлені 8.2%, що є запозиченнями, які розміщені в розділах аналізу існуючих технологій та прототипів, які не описують безпосередньо авторське дослідження і не стосуються результатів роботи.

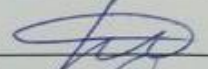
Сумарний обсяг всіх запозичень, визначений системою виявлення збігів/ідентичності/схожості, складає 0% і 8.2% відповідно, що, з урахуванням наведених обґрунтувань, відповідає характеру наукового дослідження і свідчить на користь кваліфікаційної роботи.

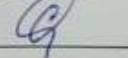
Керівник роботи

Гарант ОП

Завідувач кафедри КН







Сергій ПЕТРОВСЬКИЙ

Руслан БАГРІЙ

Олександр БАРМАК



ВІДГУК ОПОНЕНТА

на кваліфікаційну роботу магістра

гр. КНМ-22-1 Смоліснка Данила Валентиновича за темою: Метод прогнозування забруднення доріг на основі підходу глибокого активного навчання

1. Актуальність обраної теми

Обрана тема магістерської роботи є актуальною в галузі комп'ютерних наук, оскільки розглядає потребу в ефективних методах прогнозування забруднення доріг. Актуальність теми обґрунтовується проведеними дослідженнями в даній області. Вирішити задачу допомогли підхід глибокого активного навчання та використання нейромережових моделей.

2. Відповідність роботи предметній області спеціальності 122 Комп'ютерні науки та загальним вимогам до наукових робіт

Тематика кваліфікаційної роботи відповідає вимогам предметної області спеціальності 122 Комп'ютерні науки, оскільки пов'язана з теоретичними та практичними задачами в галузі комп'ютерних наук та вимогам до наукових робіт освітньо-кваліфікаційного рівня магістра.

3. Повнота розкриття мети та завдань дослідження

Мета й завдання дослідження були докладно описані в магістерській роботі, забезпечивши чітке розуміння цілей та сформульованої проблеми дослідження в рамках обраної теми. У роботі детально описується основна мета й ретельно аналізується кожне завдання, що розкриває суть кваліфікаційної роботи в повному обсязі.

4. Наявність наукової новизни

Запропоновано метод прогнозування забруднення доріг. Це досягається за рахунок використання підходу глибокого активного навчання. Також вдосконалено нейромережеві моделі для визначення та прогнозування рівня забруднення на дорозі. Проведене дослідження було опубліковано на XV Всеукраїнській науково-практичній конференції «Актуальні проблеми комп'ютерних наук АПКН-2023» 2023 р., м. Хмельницький, Україна.

5. Зміст кожного розділу роботи

Кваліфікаційна робота магістра складається із чотирьох розділів. У першому розділі, автором було проаналізовано предметну область прогнозування забруднення доріг за підходом глибокого активного навчання, здійснено дослідження існуючих наукових робіт та

публікацій близьких до тематики даної роботи, та сформульовано постановку завдань для розробки методу.

У другому розділі проведено детальний аналіз механізму та алгоритму роботи по прогнозуванню забруднення, де було використано підхід до збільшення розмірності даних, вдосконалено нейромережеву модель для визначення рівня забрудненості на дорозі та запропоновано метод прогнозування забруднення доріг.

У третьому розділі розглянуто архітектуру з компонентами інформаційної моделі та визначено засоби до реалізації методу.

У четвертому розділі проведено дослідження ефективності роботи методу, представлено результати порівняння точності розпізнавання при різній інтенсивності навчання, та показано оцінку отриманих результатів.

6. Ступінь розкриття теми роботи

У кваліфікаційній роботі магістра демонструється повний рівень розкриття обраної теми дослідження. Структура роботи побудована логічно та послідовно, кожний розділ детально описано, а поставлені завдання успішно реалізовані, що підтверджується проведенням аналізом ефективності результатів.

7. Якість оформлення кваліфікаційної роботи

Оформлення кваліфікаційної роботи було здійснено відповідно до норм та вимог. Граматичних та мовних помилок не виявлено. Наявні незначні синтаксичні помилки.

8. Недоліки кваліфікаційної роботи

У роботі приділено недостатньо уваги процесу формування датасету, що повинен включати зображення певної дороги у різний час. Це може суттєво впливати на точність та ефективність розпізнавання сутностей.

9. Загальний висновок (допускається чи не допускається до захисту), якої оцінки заслуговує кваліфікаційна робота.

Кваліфікаційна робота магістра виконана в повному обсязі, у якій продемонстровано успішне виконання всіх поставлених завдань – у результаті робота допускається до захисту. Незважаючи на присутність незначних помилок, кваліфікаційна робота заслуговує на оцінку «добре» з урахуванням загальної якості виконання та дотримання необхідних вимог.

Опонент _____



д. ф-м. н., професор Бедратюк Л.П.



**ВІДГУК НАУКОВОГО КЕРІВНИКА
на кваліфікаційну роботу магістра**

гр. КНм-22-1 Смолієнка Данило Валентиновича за темою: Метод прогнозування забруднення доріг на основі підходу глибокого активного навчання

1. Актуальність теми

Актуальність теми достатньо обгрунтована, оскільки прогнозування забруднення доріг на основі підходу глибокого активного навчання може сприяти більш ефективному розподілу ресурсів та здійснювати дієве управління забрудненням доріг.

2. Відповідність роботи предметній області спеціальності 122 Комп'ютерні науки та загальним вимогам до наукових робіт

Теми кваліфікаційної роботи "Метод прогнозування забруднення доріг на основі підходу глибокого активного навчання" відповідає предметній області спеціальності 122 Комп'ютерні науки та вимогам до кваліфікаційної роботи магістра, оскільки об'єктом дослідження є процес прогнозування забруднення доріг на основі підходу глибокого активного навчання, а саме використання моделі нейронної мережі для визначення забрудненості, предметом дослідження – методи прогнозування забруднення доріг, моделі нейронної мережі для визначення забрудненості та здійснення прогнозу.

3. Професійні та особистісні якості магістранта

Смолієнко Д.В. під час роботи над кваліфікаційною роботою магістра продемонстрував високий рівень знань та умінь за спеціальністю "Комп'ютерні науки".

4. Ступінь самостійності під час виконання кваліфікаційної роботи

Робота виконана самостійно, академічного плагіату не виявлено, стосовно всіх запозичень наведено відповідні посилання на джерела.

5. Наукова новизна та оригінальність запропонованих підходів

Отримані такі результати: вдосконалено нейромережеві моделі для визначення рівня забрудненості доріг на зображенні та для прогнозування рівня забруднення. Було використано поєднання кращих особливостей декількох нейромережевих моделей – CNN, LSTM, повнозв'язних шарів, що дозволило підвищити точність прогнозування рівня забруднення доріг до 97,84%. Отримані результати оприлюднені на XIII всеукраїнської науково-практичної конференції «Актуальні проблеми комп'ютерних наук АПКН-2023»,

17-18 листопада 2023 р., м. Хмельницький, Україна, доповідь на тему «Метод прогнозування забруднення доріг на основі підходу глибокого активного навчання».

6. Ступінь оволодіння методами дослідження

Студент Смолієнко Д.В. має достатньо високий ступінь володіння методами дослідження, що були використанні у роботі.

7. Повнота та якість розкриття теми роботи

Мета роботи повністю розкрита, отримані результати підтверджують достовірність наукових положень.

8. Логічність, послідовність, аргументованість, літературна грамотність викладу матеріалу

Викладення матеріалу логічне, послідовне та аргументоване. Мова і стиль викладення кваліфікаційної роботи магістра відповідають стандартам, що забезпечує доступність сприймання матеріалу і відповідає вимогам до сучасних наукових робіт.

9. Можливість практичного застосування кваліфікаційної роботи, окремих її частин

Може мати практичне значення при виявленні прогнозованої оцінки рівня забрудненості дороги, що ефективному розподілу ресурсів.

10. Висновок про можливість допуску кваліфікаційної роботи до захисту, на яку оцінку заслуговує робота

Вважаю, що кваліфікаційна робота студента Смолієнка Данило Валентиновича може бути рекомендована до захисту та заслуговує на оцінку "добре".

Науковий керівник _____



к.п.н., доц. Сергій Петровський