

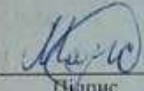
## КВАЛІФІКАЦІЙНА РОБОТА МАГІСТРА


на тему Метод виявлення забруднень навколишнього середовища на основі супутникових зображень

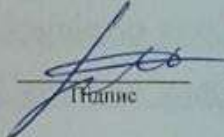
Галузь знань 12 – Інформаційні технології  
Шифр і назва галузі знань


Спеціальність 122 – Комп'ютерні науки

Освітня програма Комп'ютерні науки  
Шифр і назва спеціальності

Виконав: студент 2 курсу, група КНм-22-1  О.О. Морський  
Підпис Ініціали, прізвище

Керівник: д.т.н., професор кафедри КН  Е.А. Манзюк  
Підпис Ініціали, прізвище

Нормоконтроль: к.т.н., доцент кафедри КН  Р.О. Багрії  
Підпис Ініціали, прізвище

До захисту допускаю:  
Зав. кафедри КН, д.т.н., професор  О.В. Бармак  
Підпис Ініціали, прізвище

08 грудня 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

« 1 » 09 2023 року

**ЗАВДАННЯ  
НА КВАЛІФІКАЦІЙНУ РОБОТУ МАГІСТРА**

1. Тема кваліфікаційної роботи магістра: Метод виявлення забруднень навколишнього середовища на основі супутникових зображень

2. Завдання видано студенту Морському Олександру Олексійовичу  
(прізвище, ім'я, по батькові)

3. Керівник роботи д.т.н. Манзюк Едуард Андрійович  
(прізвище, ім'я, по батькові)

4. Затверджені наказом університету від « 15 » 08 2023 р. № 30

5. Зміст пояснювальної записки (перелік задач) та вихідні дані:

Мета роботи – розробка методу виявлення забруднень навколишнього середовища на основі супутникових зображень, особливістю якого є розробка та налаштування нейронної мережі для точної ідентифікації та класифікації різних видів стихійних сміттєзвалищ, незалежно від їх походження. Дослідження включає в себе класифікацію супутникових знімків. Використання глибокого навчання, такого як нейронні мережі, дозволить автоматично виділити особливості сміттєзвалищ на зображеннях і встановити їх присутність або відсутність. Класифікація різних типів відходів, яка включає в себе ідентифікацію різних типів відходів на супутникових знімках, що показують наявність сміттєзвалищ. Особливістю дослідження є розробка та налаштування нейронної мережі на ідентифікацію та класифікацію стихійних сміттєзвалищ різної природи походження.

## Реферат

Кваліфікаційна робота магістра вирішує науково-практичне завдання розробки методу виявлення забруднень навколишнього середовища на основі супутникових зображень, особливістю якого є розробка та налаштування нейронної мережі для точної ідентифікації та класифікації різних видів стихійних сміттєзвалищ, незалежно від їх походження.

**Актуальність теми.** Забруднення навколишнього середовища є серйозною загрозою для здоров'я людей та природного середовища. Викиди шкідливих речовин, стихійні сміттєзвалища та інші форми забруднення, мають серйозний вплив на якість повітря, води та ґрунту. Завдяки сучасним супутниковим технологіям, маємо доступ до великої кількості супутникових зображень, які охоплюють великі території та збирають дані в реальному часі. Ця доступність дозволяє ефективно використовувати супутникові дані для виявлення забруднень. Сучасні методи машинного навчання та глибокого навчання виявилися ефективними для аналізу великих обсягів даних. Застосування цих методів до супутникових зображень дозволяє автоматизувати процес виявлення забруднень, включаючи стихійні сміттєзвалища, зміни в рослинному покриві та інші види забруднень. Відповідно до міжнародних стандартів та нормативів, країни зобов'язані моніторити стан навколишнього середовища та вчасно реагувати на забруднення. Використання супутникових зображень та аналітичних методів дозволяє покращити процес моніторингу та забезпечити точні та актуальні дані.

Проблеми забруднення навколишнього середовища стали глобальними викликами, які вимагають уваги та практичних дій на міжнародному рівні. Відслідковування та виявлення забруднень за допомогою супутникових зображень може бути корисним інструментом у боротьбі з цими проблемами.

Усі ці фактори підкреслюють важливість та актуальність теми дослідження методів виявлення забруднень навколишнього середовища на основі супутникових зображень. Розвиток і застосування таких методів може

сприяти покращенню якості довкілля та здійснити внесок до збереження навколишнього середовища.

**Мета і задачі роботи.** Мета кваліфікаційної роботи магістра полягає в розробці та використанні сучасних методів глибокого навчання для ефективної ідентифікації стихійних сміттєзвалищ на супутникових знімках. Дослідження включає в себе класифікацію супутникових знімків. В процесі дослідження необхідно розробити методи для класифікації супутникових знімків на дві групи – ті, на яких видно сміттєзвалища, і ті, на яких їх відсутні. Використання глибокого навчання, такого як нейронні мережі, дозволить автоматично виділити особливості сміттєзвалищ на зображеннях і встановити їх присутність або відсутність. Класифікація різних типів відходів, яка включає в себе ідентифікацію різних типів відходів на супутникових знімках, що показують наявність сміттєзвалищ. Це може включати в себе розрізнення між пластиковими, металевими, органічними та іншими видами сміття. Глибоке навчання дозволить автоматизувати цей процес і визначити типи відходів на знімках. Особливістю дослідження є розробка та налаштування нейронної мережі на ідентифікацію та класифікацію стихійних сміттєзвалищ різної природи походження.

В ході дослідження та реалізації магістерської роботи необхідно вирішити наступні основні завдання:

1. Провести огляд наукової літератури та методів, пов'язаних із застосуванням глибокого навчання для ідентифікації сміттєзвалищ на супутникових знімках та класифікації відходів.

2. Здійснити вибір та збір супутникових зображень для дослідження, а також розробку методів обробки та підготовки цих даних для подальшого аналізу.

3. Розробити метод виявлення забруднень навколишнього середовища на основі супутникових зображень.

4. Провести тестування розробленого методу на відповідних супутникових зображеннях для оцінки її точності та ефективності.

**Об'єкт дослідження** – процес виявлення забруднень навколишнього середовища на основі супутникових зображень.

**Предмет дослідження** – моделі, методи, алгоритми та засоби навчання нейронних мереж для виявлення забруднень навколишнього середовища.

**Методи дослідження**, які застосовані для вирішення поставлених завдань, наступні: методи аналізу даних та теорії множин, методи проектування інформаційних систем, методи глибокої мереж, алгоритми загорткових нейронних мереж.

**Наукова новизна одержаних результатів** Результати виконання кваліфікаційної роботи магістра містять наукову новизну, зокрема було удосконалено метод виявлення забруднень навколишнього середовища на основі супутникових зображень, який дозволяє для визначеного набору супутникових знімків в вигляді забруднених та чистих ділянок, з використанням значень параметрів максимальної та мінімальної інтенсивності пікселів зображень та площі ділянок забруднень, одержувати вихідні дані у вигляді результатів ідентифікації та класифікації стихійних сміттєзвалищ та класифікації видів забруднень сміття за зображеннями. Цей метод відрізняється від існуючих тим, що дозволяє автоматично виділити особливості забруднень на зображеннях і встановити їх присутність або відсутність, забезпечуючи точну ідентифікацію та класифікацію стихійних сміттєзвалищ і видів сміття на супутникових зображеннях.

**Практичне значення одержаних результатів.** В результаті проведених наукових досліджень було розроблено систему для ідентифікації стихійних звалищ за супутниковими зображеннями. Проведені дослідження показали загальну ефективність спроектованої системи ідентифікації та класифікації звалищ. Варто відзначити, що ефективність такої моделі в значній мірі залежить від розміру набору даних та тривалості процесу навчання. При належному налаштуванні параметрів моделі та використанні широкого та різноманітного набору даних, вона може досягти високого рівня точності класифікації. Це, в

свою чергу, сприяє більш ефективному вирішенню проблеми незаконного сміття і сприяє переходу до більш сталого та циркулярного використання ресурсів.

Для поліпшення точності класифікації, проводилось навчання кількох моделей глибокого навчання з використанням згорткових нейронних мереж на відносно невеликому наборі даних, який включав два абсолютно відмінні класи відходів.

Моделі були піддані навчанню на цих даних з метою детектування двох різних класів відходів. У порівнянні з попереднім набором даних, цей був суттєво меншим за обсягом. Шляхом застосування методів розширення даних для компенсації цього обмеження вдалося досягти рівня точності класифікації на рівні 82%.

В дослідженні був використаний обмежений набір даних, і це може бути однією з його обмежень. Однак, розвиток моделей глибокого навчання в поєднанні з високороздільними супутниковими знімками може стати перспективним напрямком для вирішення проблеми незаконного скидання відходів за умови вдосконалення методології та впровадження нових підходів.

**Апробація результатів кваліфікаційної роботи магістра та публікації.** Одержані наукові і практичні результати кваліфікаційної роботи магістра доповідались в доповіді на тему «Виявлення забруднень навколишнього середовища методами штучного інтелекту з використанням супутникових зображень» на XV Всеукраїнській науково-практичній конференції «Актуальні проблеми комп'ютерних наук АПКН-2023» (17-18 листопада 2023 року); за темою роботи автором виконано наукову публікацію:

Морський О.О., Лукманов Т.К., Манзюк Е.А. Виявлення забруднень навколишнього середовища методами штучного інтелекту з використанням супутникових зображень. Збірник наукових праць за матеріалами XV Всеукраїнської науково-практичної конференції «Актуальні проблеми комп'ютерних наук АПКН-2023». Хмельницький, 2023. с. 201-202.

**Структура і обсяг роботи.** Кваліфікаційна робота магістра складається з наступного: реферату, завдання, змісту, переліку скорочень, вступу, 4 розділів,

висновків, переліку посилань з 41 найменування й 2 додатків. Загальний обсяг кваліфікаційної роботи магістра становить 95 сторінок, із них 76 сторінок основного тексту й 9 сторінок додатків. В роботі наведено 12 рисунків й 5 таблиць.

**Ключові слова:** нейронна мережа, згортова нейронна мережа, архітектура нейронної мережі, інформаційна система, інформаційна модель.

## Зміст

Вступ.....	4
Розділ 1	
Системи машинного навчання для класифікації зображень .....	9
1.1 Опис предметної області .....	9
1.2 Аналіз характеристик супутникових зображень з отримання інформації... ..	10
1.3 Характеристики супутникових сенсорів .....	11
1.4 Мультимодальне навчання за допомогою моделі глибокого навчання.....	14
Постановка задачі.....	21
Висновки до розділу 1 .....	22
Розділ 2	
Метод виявлення забруднень навколишнього середовища на основі супутникових зображень .....	24
2.1 Моделі загорткової мережі з використанням супутникових знімків .....	24
2.2 Формування даних для навчання моделей нейронної мережі.....	29
2.3 Проектування нейронної мережі з використанням контурів зворотного зв'язку.....	31
2.4 Класифікація на основі бінарного підходу.....	34
2.5 Ітерації моделі та порівняння ефективності моделей .....	38
2.6 Класифікація видів відходів.....	40
Висновки до розділу 2 .....	43
Розділ 3	
Інформаційна система виявлення забруднень навколишнього середовища на основі супутникових зображень .....	44
3.1 Попереднє оброблення даних зображення .....	44
3.2 Реалізація та аналіз моделей .....	49
3.3 Попереднє опрацювання масиву даних .....	55
3.4 Адаптація моделі до набору даних.....	57
Висновки до розділу 3 .....	61

## Розділ 4

Дослідження ефективності системи виявлення забруднень навколишнього середовища на основі супутникових зображень.....	62
4.1 Оцінювання якісних характеристик класифікації .....	62
4.2 Класифікація типів звалищ .....	63
4.3 Класифікація видів відходів.....	65
Висновки до розділу 4 .....	71
Загальний висновок.....	73
Перелік посилань.....	75
Додатки.....	80
Додаток А .....	81
Додаток Б.....	83

## Вступ

Кваліфікаційна робота магістра вирішує науково-практичне завдання розробки методу виявлення забруднень навколишнього середовища на основі супутникових зображень, особливістю якого є розробка та налаштування нейронної мережі для точної ідентифікації та класифікації різних видів стихійних сміттєзвалищ, незалежно від їх походження.

**Актуальність теми.** Забруднення навколишнього середовища є серйозною загрозою для здоров'я людей та природного середовища. Викиди шкідливих речовин, стихійні сміттєзвалища та інші форми забруднення, мають серйозний вплив на якість повітря, води та ґрунту. Завдяки сучасним супутниковим технологіям, маємо доступ до великої кількості супутникових зображень, які охоплюють великі території та збирають дані в реальному часі. Ця доступність дозволяє ефективно використовувати супутникові дані для виявлення забруднень. Сучасні методи машинного навчання та глибокого навчання виявилися ефективними для аналізу великих обсягів даних. Застосування цих методів до супутникових зображень дозволяє автоматизувати процес виявлення забруднень, включаючи стихійні сміттєзвалища, зміни в рослинному покриві та інші види забруднень. Відповідно до міжнародних стандартів та нормативів, країни зобов'язані моніторити стан навколишнього середовища та вчасно реагувати на забруднення. Використання супутникових зображень та аналітичних методів дозволяє покращити процес моніторингу та забезпечити точні та актуальні дані.

Проблеми забруднення навколишнього середовища стали глобальними викликами, які вимагають уваги та практичних дій на міжнародному рівні. Відслідковування та виявлення забруднень за допомогою супутникових зображень може бути корисним інструментом у боротьбі з цими проблемами.

Усі ці фактори підкреслюють важливість та актуальність теми дослідження методів виявлення забруднень навколишнього середовища на

основі супутникових зображень. Розвиток і застосування таких методів може сприяти покращенню якості довкілля та здійснити внесок до збереження навколишнього середовища.

**Мета і задачі роботи.** Мета кваліфікаційної роботи магістра полягає в розробці та використанні сучасних методів глибокого навчання для ефективної ідентифікації стихійних сміттєзвалищ на супутникових знімках. Дослідження включає в себе класифікацію супутникових знімків. В процесі дослідження необхідно розробити методи для класифікації супутникових знімків на дві групи на яких видно сміттєзвалища, і на яких сміттєзвалища відсутні. Використання глибокого навчання, такого як нейронні мережі, дозволить автоматично виділити особливості сміттєзвалищ на зображеннях і встановити їх присутність або відсутність. Класифікація різних типів відходів, яка включає в себе ідентифікацію різних типів відходів на супутникових знімках, що показують наявність сміттєзвалищ. Це може включати в себе розрізнення між пластиковими, металевими, органічними та іншими видами сміття. Глибоке навчання дозволить автоматизувати цей процес і визначити типи відходів на знімках. Особливістю дослідження є розробка та налаштування нейронної мережі на ідентифікацію та класифікацію стихійних сміттєзвалищ різної природи походження.

В ході дослідження та реалізації магістерської роботи необхідно вирішити наступні основні завдання:

1. Провести огляд наукової літератури та методів, пов'язаних із застосуванням глибокого навчання для ідентифікації сміттєзвалищ на супутникових знімках та класифікації відходів.

2. Здійснити вибір та збір супутникових зображень для дослідження, а також розробку методів обробки та підготовки цих даних для подальшого аналізу.

3. Розробити метод виявлення забруднень навколишнього середовища на основі супутникових зображень.

4. Провести тестування розробленого методу на відповідних супутникових зображеннях для оцінки її точності та ефективності.

**Об'єкт дослідження** – процес виявлення забруднень навколишнього середовища на основі супутникових зображень.

**Предмет дослідження** – моделі, методи, алгоритми та засоби навчання нейронних мереж для виявлення забруднень навколишнього середовища.

**Методи дослідження**, які застосовані для вирішення поставлених завдань, наступні: методи аналізу даних та теорії множин, методи проектування інформаційних систем, методи глибоких мереж, алгоритми загорткових нейронних мереж.

**Наукова новизна одержаних результатів** Результати виконання кваліфікаційної роботи магістра містять наукову новизну, зокрема було удосконалено метод виявлення забруднень навколишнього середовища на основі супутникових зображень, який дозволяє для визначеного набору супутникових знімків у вигляді забруднених та чистих ділянок, з використанням значень параметрів максимальної та мінімальної інтенсивності пікселів зображень та площі ділянок забруднень, одержувати вихідні дані у вигляді результатів ідентифікації та класифікації стихійних сміттєзвалищ та класифікації видів забруднень сміття за зображеннями. Цей метод відрізняється від існуючих тим, що дозволяє автоматично виділити особливості забруднень на зображеннях і встановити їх присутність або відсутність, забезпечуючи точну ідентифікацію та класифікацію стихійних сміттєзвалищ і видів сміття на супутникових зображеннях.

**Практичне значення одержаних результатів.** В результаті проведених наукових досліджень було розроблено систему для ідентифікації стихійних звалищ за супутниковими зображеннями. Проведені дослідження показали загальну ефективність спроектований системи ідентифікації та класифікації звалищ. Варто відзначити, що ефективність такої моделі в значній мірі залежить від розміру набору даних та тривалості процесу навчання. При належному

налаштуванні параметрів моделі та використанні широкого та різноманітного набору даних, вона може досягти високого рівня точності класифікації. Це, в свою чергу, сприяє більш ефективному вирішенню проблеми незаконного скидання відходів і сприяє переходу до більш сталого та циркулярного використання ресурсів.

Для поліпшення точності класифікації, проводилось навчання кількох моделей глибокого навчання з використанням згорткових нейронних мереж на відносно невеликому наборі даних, який включав два абсолютно відмінні класи відходів.

Моделі були піддані навчанню на цих даних з метою детектування двох різних класів відходів. У порівнянні з попереднім набором даних, цей був суттєво меншим за обсягом. Шляхом застосування методів розширення даних для компенсації цього обмеження вдалося досягти рівня точності класифікації на рівні 82%.

В дослідженні був використаний обмежений набір даних, і це може бути однією з його обмежень. Однак, розвиток моделей глибокого навчання в поєднанні з високороздільними супутниковими знімками може стати перспективним напрямком для вирішення проблеми незаконного скидання відходів за умови вдосконалення методології та впровадження нових підходів.

**Апробація результатів кваліфікаційної роботи магістра та публікації.** Одержані наукові і практичні результати кваліфікаційної роботи магістра доповідались в доповіді на тему «Виявлення забруднень навколишнього середовища методами штучного інтелекту з використанням супутникових зображень» на XV Всеукраїнській науково-практичній конференції «Актуальні проблеми комп'ютерних наук АПКН-2023» (17-18 листопада 2023 року); за темою роботи автором виконано наукову публікацію:

Морський О.О., Лукманов Т.К., Манзюк Е.А. Виявлення забруднень навколишнього середовища методами штучного інтелекту з використанням супутникових зображень. Збірник наукових праць за матеріалами XV

Всеукраїнської науково-практичної конференції «Актуальні проблеми комп'ютерних наук АПКН-2023». Хмельницький, 2023. с. 201-202.

**Структура і обсяг роботи.** Кваліфікаційна робота магістра складається з наступного: реферату, завдання, змісту, вступу, 4 розділів, висновків, переліку посилань з 41 найменування й 2-х додатків. Загальний обсяг кваліфікаційної роботи магістра становить 95 сторінок, із них 76 сторінок основного тексту й 9 сторінок додатків. В роботі наведено 12 рисунків й 5 таблиць.

## **Розділ 1**

### **Системи машинного навчання для класифікації зображень**

#### **1.1 Опис предметної області**

Мета магістерської роботи полягає в дослідженні можливостей використання сучасних методів глибокого навчання в поєднанні з супутниковими знімками для ідентифікації відходів на стихійних сміттєзвалищах. Це включає в себе два аспекти: класифікацію супутникових знімків, на яких видно сміттєзвалища та тих, на яких їх немає, а також класифікацію різних типів відходів на супутникових знімках, які показують наявність сміттєзвалищ.

Для успішної реалізації мети важливо мати розуміння наявних наборів даних супутникових знімків та їх характеристик. В сучасному споживчому суспільстві виробляється значна кількість відходів, і ця проблема лише поглиблюється протягом останнього десятиліття. Дефіцит належної утилізації відходів призводить до незаконних захоронень, які мають серйозні негативні наслідки для навколишнього середовища та прилеглих житлових районів. Один із очевидних виявів цього явища – забруднення ґрунту та підземних вод, що має критичне значення для сільського господарства. Проживання поруч з нелегальними звалищами становить ризик для здоров'я населення. Також ці незаконні звалища негативно впливають на розвиток туризму, що може серйозно підірвати економіку населених пунктів, які значною мірою залежать від туристичної галузі. З урахуванням широкого спектру видів відходів, що викидаються, державним органам важко відслідковувати та усувати стихійні звалища. Для успішного боротьби з цією проблемою необхідно точно визначити місцезнаходження стихійних відходів та правильно класифікувати їхні типи. Ця класифікація важлива для просування в напрямку циркулярної економіки та боротьби з незаконними захороненнями відходів.

Для ефективної боротьби з нелегальними захороненнями відходів необхідно точно визначити тип матеріалу, що був скинутий, для подальшого зв'язку з відповідними організаціями, які здійснюють очищення. Ці організації володіють знаннями про процеси переробки конкретних матеріалів, що дозволяє максимально збільшити кількість матеріалів, які можуть бути відновлені та перероблені.

Такий підхід до використання ресурсів у контексті циркулярної економіки, крім очевидних природоохоронних переваг, має і значні економічні переваги, включаючи економію витрат. Для реалізації цієї ідеї необхідно розробити технологію автоматичного виявлення стихійних захоронень та точної класифікації матеріалів, що були викинуті та сформували стихійні звалища. Використання глибокого навчання в поєднанні з дистанційним зондуванням, тобто спостереженням за землею за допомогою датчиків на супутниках або літаках, вже було успішно використано в різних аналогічних застосунках.

## **1.2 Аналіз характеристик супутникових зображень з отримання інформації**

Існує кілька різних типів супутникових датчиків, які використовуються для отримання супутникових даних, і всі вони належать до однієї з двох основних категорій [20, 25, 41]. Перша основна категорія датчиків – це датчики формування зображень. У категорії датчиків зображення є такі підкатегорії, як датчики оптичного, датчики теплового і датчики радіолокаційного зображення. Оптичні датчики визначаються тим, що вони здатні сприймати електромагнітні хвилі у видимій частині спектра або хвилі, відбиті від поверхні землі. З іншого боку, теплові датчики працюють в інфрачервоному і мікрохвильовому діапазонах. Радарні датчики зображення є активними датчиками в мікрохвильовому діапазоні.

Оптичні датчики, які виявляють електромагнітні хвилі у видимому спектрі або реєструють відбиті від поверхні землі хвилі, стали невід'ємною частиною систем відстеження та розпізнавання об'єктів. Ці датчики застосовуються в різних галузях, включаючи військову техніку, безпеку та виробництво, де важлива висока точність і швидкість виявлення. Теплові датчики, що операційно працюють у інфрачервоному і мікрохвильовому діапазонах, забезпечують можливість вимірювання теплового випромінювання об'єктів.

Вони знаходять своє використання у термовізійних системах, медичних дослідженнях та автоматизованих системах виробництва для виявлення аномалій в температурі. Радарні датчики зображення використовують активний метод в мікрохвильовому діапазоні, що надає їм можливість працювати в різних погодних умовах і навіть проникати через туман та інші атмосферні перешкоди. Вони застосовуються в автомобільній промисловості, метеорологічних системах та в оборонній сфері для високоточного зображення об'єктів.

Ці технології датчиків сприяють розвитку сучасних систем моніторингу, безпеки та автоматизації, роблячи їх ефективнішими та надійнішими у різноманітних сценаріях застосування.

Друга категорія включає в себе датчики, які не формують зображення. Сюди входять спектро радіометри, радіометри та лазерні датчики. Також варто відзначити набори даних Lidar (Light Detection and Ranging), які базуються на використанні лазерних датчиків [17, 27, 28, 33].

Зазвичай ці види датчиків не мають широкого застосування, за винятком Lidar, який зазвичай використовується для картографування. В контексті супутникових знімків набори даних, що не включають зображень, можуть мати обмежений потенціал у порівнянні з наборами даних, що базуються на зйомці.

### **1.3 Характеристики супутникових сенсорів**

Супутникові сенсори мають кілька важливих характеристик, які впливають на дані, отримані за їхньою допомогою. Серед них важливі такі параметри, як просторова роздільна здатність, час обертання та розмір смуги захоплення. Ці характеристики змінюються в залежності від конкретних супутників, які надають доступ до наборів даних.

Також важливий тип сенсора, який використовується супутником для збору даних. Якщо це оптичний сенсор, то його специфіку характеризують спектральний діапазон і кількість спектральних смуг. Спектральний діапазон вказує на діапазон довжин хвиль спектра, які може реєструвати датчик. Оптичні сенсори можуть бути одноканальними з коротким спектральним діапазоном, мультिकанальними з середнім спектральним діапазоном, розділеним на декілька смуг, або гіперспектральними з великим спектральним діапазоном, поділеним на багато малих спектральних смуг. Інші характеристики можуть відрізнятися як для оптичних, так і для інших типів супутникових сенсорів.

Ще однією ключовою характеристикою набору супутникових даних є просторова роздільна здатність [6, 9, 11, 29]. Ця характеристика використовується для розрізнення між різними супутниками. Просторова роздільна здатність визначає фактичний розмір кожного пікселя на супутниковому зображенні в порівнянні з реальним розміром об'єкта. Цей параметр вказує на те, наскільки дрібним може бути відображуваний об'єкт для сенсорів і може коливатися від кількох кілометрів до декількох дециметрів.

Час повторного відвідування – це інша важлива характеристика, яка вказує на інтервал часу, необхідний супутнику для повторного вимірювання того ж місця після попереднього проходу. Цей інтервал зазвичай коливається від кількох діб до кількох місяців.

Розмір смуги захоплення також використовується для розрізнення між супутниками і вказує на ширину області, яку датчик захоплює під час кожного проходу. Ця ширина може бути декілька сотень кілометрів.

Крім цього, інші фактори, не пов'язані з характеристиками датчика, такі як доступність і доступні набори даних, можуть впливати на вибір конкретного набору даних для конкретного застосування. Доступні набори даних мають різноманітні характеристики, які слід враховувати в залежності від конкретної ситуації, і деякі з цих характеристик можуть мати більший вплив на вибір, ніж інші.

У процесі класифікації супутникових знімків з використанням глибокого навчання, різні характеристики впливають на точність класифікації в різній мірі. Зазвичай найбільший вплив на точність має просторова роздільна здатність, після чого слід враховувати вибір спектрального діапазону в залежності від конкретного використання. Інші характеристики зазвичай мають менший вплив на точність класифікації.

Зміна просторової роздільної здатності під час класифікації супутникових знімків може призвести до найбільшого приросту точності класифікації. Важливо зауважити, що вплив високої роздільної здатності може варіюватися в залежності від конкретних ландшафтів, які класифікуються, і вища роздільна здатність не завжди гарантує більш точну класифікацію, оскільки це залежить від конкретних умов і об'єктів, які досліджуються.

Після встановлення оптимальної просторової роздільної здатності виявлено, що вибір спектрального діапазону також має значний вплив на точність класифікації. Важливо ретельно обирати спектральний діапазон, оскільки додавання додаткових спектральних смуг не завжди призводить до підвищення точності класифікації.

Вплив вибору спектрального діапазону на точність набагато більший, ніж просторової роздільної здатності. Тому використання більшої кількості спектральних смуг зазвичай призводить до кращих результатів.

Варто відзначити, що ця відмінність може бути пов'язана з різницею в ландшафтах і цілях досліджень. Вплив різних характеристик на точність класифікації може варіюватися залежно від конкретного використання. Проте на

загальному рівні найважливішими факторами залишаються просторова роздільна здатність і вибір спектрального діапазону.

Для ефективної ідентифікації відходів, важливо використовувати супутникові знімки з високою просторовою роздільною здатністю. Окрім смуг візуального спектра, ближні інфрачервоні та короткохвильові інфрачервоні діапазони мають велике значення для розрізнення різних матеріалів ґрунтового покриву.

Зокрема, точність класифікації ґрунтово-рослинного покриву в містах значно покращується, коли враховуються додаткові спектральні смуги, такі як червоний, ближній інфрачервоний, жовтий видимий та видимий синій діапазони спектра.

Це дозволяє досягти більш високої точності при класифікації і відокремленні різних видів матеріалів на знімках.

#### **1.4 Мультимодальне навчання за допомогою моделі глибокого навчання**

Незважаючи на те, що для певних наборів даних оптичне фотографування є найбільш корисним, можна досягти ще більшої точності класифікації, поєднуючи різні види супутникових даних або дані, зібрані різними методами, за допомогою глибокого навчання. Цей підхід дозволяє підвищити точність класифікації, об'єднуючи високо роздільні супутникові дані з даними лазерної зйомки та радарними даними [13, 14, 16, 22, 32].

Додавання оптичних ознак до спектральних смуг, які спочатку використовувалися, може бути важливим кроком у підвищенні точності класифікації. Оптичні ознаки можуть слугувати додатковими даними, які можуть бути використані для поліпшення результатів класифікації вже наявним набором даних.

Нейронні мережі представляють собою вид глибокого навчання, який складається зі шарів нейронів або вузлів, що взаємодіють між собою. В кожному нейроні вхідний сигнал піддається обробці шляхом застосування певних ваг та зміщень, після чого видається вихідний сигнал через функцію активації. Завдяки використанню методу зворотного поширення помилки та функції вартості, ваги в нейронній мережі можуть бути налаштовані для розпізнавання конкретних шаблонів або виконання певних завдань.

Згорткові нейронні мережі (convolutional neural network – CNN) є підтипом нейронних мереж, які особливо корисні для аналізу та вивчення патернів на зображеннях [7, 23, 26, 34, 38, 39]. Вони володіють спеціалізованою архітектурою та здатністю ефективно аналізувати дані та виявляти візуальні особливості в даних, зокрема у зображеннях.




Рисунок 1.1 – Діаграма нейронної мережі [1]

Згорткові мережі демонструють значний успіх у різних галузях. Вони особливо ефективні в класифікації зображень завдяки декільком ключовим характеристикам. Операція згортки, яка обробляє групи пікселів, дозволяє виділити абстрактні ознаки з вихідних даних, які далі використовуються для

класифікації. Згорткові мережі мають властивість отримувати інформацію з масивів даних, завдяки об'єднуючим шарам у їх структурі. Використання розріджених зв'язків, розділення ваг та просторового підсемплінгу сприяє адаптації до структури вхідних зображень.

Порівнюючи згорткові мережі з традиційними нейронними мережами та моделями випадкового лісу, вони демонструють вищу точність класифікації в даному випадку. Згорткові мережі виходять на передову за високими показниками точності, що враховують їхню ефективність у сфері класифікації [2, 8, 10, 15, 18, 19, 30].

Структура згорткової мережі включає в себе два основних типи шарів: згорткові та пулінгові. Імена цим шарам надані відповідно до їхніх функцій. Схему цієї структури можна побачити на рисунку 1.2.

Архітектура згорткової мережі складається з різних компонентів, які організовані у шари [4, 5, 21, 24, 31, 36]. Ці шари можна розділити на дві основні частини: частину для виділення ознак та частину для класифікації цих ознак. Перша частина призначена для отримання вхідних даних та перетворення їх на набір ознак, які можуть бути присутні на початковому зображенні. Ці ознаки можуть включати в себе, наприклад, різні лінії, текстури або шаблони.

Інша частина, яка відповідає за класифікацію ознак, визначає, яким чином класифікувати вхідне зображення на основі виділених ознак. У цій частині мережі шари повністю пов'язані між собою, схоже до традиційних нейронних мереж з глибокими зв'язками. Однак в шарах, які відповідають за виділення ознак, кожен нейрон взаємодіє тільки з обмеженою областю попереднього шару.

Згортковий шар виконує операцію згортки, яка оперує над невеликим фрагментом вхідного зображення, визначеним розміром ядра згортки. Це ядро фактично є фільтром, представленим матрицею ваг, і воно застосовується до значень пікселів в межах обраної області.

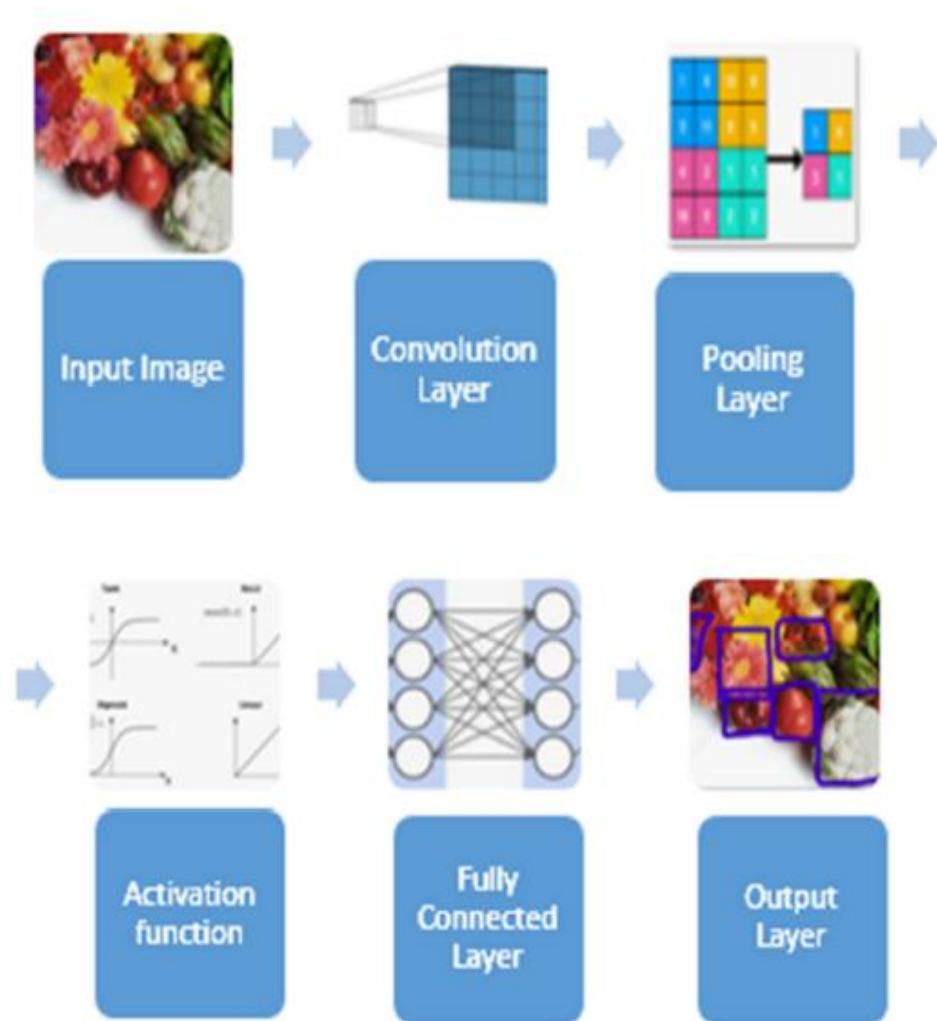


Рисунок 1.2 – Діаграма CNN [5]

Шляхом обчислення середнього зваженого значення входів ця операція створює вихід для даного фрагмента, і коли ця операція виконується для всіх фрагментів зображення, утворюється згорнуте зображення. Це згорнуте зображення може бути подано як вхід для наступного шару з метою виділення більш складних ознак з кожним новим шаром.

Об'єднувальний шар використовується для зменшення обчислювальних витрат під час навчання мережі за допомогою процедури субдискретизації вхідного зображення. Суть полягає в тому, що певні ознаки зображення виділяються, а вхідні дані зменшуються, допомагаючи моделі ефективно навчати ознаки з меншими обчислювальними витратами. Подібно до згорткового шару,

об'єднувальний шар використовує ядро для визначення, яка частина вхідних даних залишиться. Проте, важливо зауважити, що об'єднувальний шар не виконує операції згортки; натомість він може використовувати різні види шарів об'єднання, такі як максимальне, середнє та випадкове об'єднання. Ці шари обирають максимальне, середнє або випадкове значення пікселів всередині ядра, в залежності від вибраного методу об'єднання.

Функція активації відіграє значну роль в контексті загорткової мережі, оскільки вона визначає, чи буде нейрон активним чи неактивним. До недавнього часу популярною була сигмоїдальна функція активації, однак зараз більш часто використовують функції ReLU [12, 35, 37]. Ця функція визначає, чи активується нейрон, враховуючи його вхід.

Функція втрат використовується для вимірювання різниці між передбаченою відповіддю нейрона та очікуваною відповіддю. Крос-ентропія є популярним вибором для функції втрат, оскільки вона прискорює навчання, коли передбачення значно відхиляється від очікуваного результату. Деякі методи регуляризації можуть бути використані, щоб запобігти перенавчанню моделі.

Частина класифікатора ознак включає повністю зв'язані шари, які містять кілька прихованих шарів, складених з повністю зв'язаних нейронів. Ці повністю зв'язані шари приймають вхідні ознаки у вигляді одновимірного вектора, який отримано з попередніх шарів загорткової мережі, і передають їх на вихідний шар, який проводить класифікацію за допомогою певної функції класифікації, такої як машини опорних векторів.

Важливо відзначити, що існує безліч моделей загорткових мереж, кожна з яких володіє власною структурою та особливостями. Перелік моделей загорткової мережі наведено в таблиці 1.1.

Модель LeNet, розроблена вперше в 1990 році і пізніше вдосконалена у 1998 році, вважається першою згортковою нейронною мережею, створеною для класифікації рукописного тексту. Її структура включає два згорткові шари позначені як С-шари і два об'єднуючих шари позначені як Р-шари, які

чергуються. LeNet відіграла ключову роль в історії розвитку глибокого навчання і послужила основою для подальших наукових досліджень в цій області [40].

Таблиця 1.1 – Огляд моделей CNN

Модель	Конструктивні особливості
ResNet100	1 x 1 фільтри
VGG	Максимальне об'єднання
LeNet	Проста структура CNN
ResNet	Пакетна нормалізація

Модель VGG, також відома як VGGNet, була створена для дослідження потенціалу глибоких згорткових нейронних мереж. Перша версія VGG містила 19 шарів і визначила важливість глибини мережі для досягнення високої точності класифікації. Ця модель стала кроком вперед у розвитку глибокого навчання і відкрила широкі перспективи для подальших досліджень у цій галузі, а також для класифікації.

Модель ResNet, що виникла на основі 19-шарової моделі VGG, розширила глибину мережі на 34 шари. Важливою інновацією в ResNet було введення пропускових, залишкових з'єднань, які сприяють прискоренню навчання нейронної мережі та вирішують проблему вигорання градієнту. Крім того, в моделі ResNet використовується батч-нормалізація для поліпшення швидкості та стабільності навчання. Пізніше в ітераціях моделі ResNet, вона була розширена до більш ніж 1000 шарів, що призвело до хороших результатів у завданнях класифікації.

Різні моделі, зокрема ResNet100, розширили структуру оригінальної моделі, додавши пропускові з'єднання. Ця інновація значно покращила процес навчання, дозволяючи моделям вивчати інформацію швидше та ефективніше [3].

Згорткові нейронні мережі в історії розвитку глибокого навчання відіграли важливу роль, значно покращуючи ефективність та точність обробки зображень і розпізнавання об'єктів на них.

Всі ці моделі глибокого навчання іноді називають етапами або кроками у розвитку мереж для обробки зображень. Кожен наступний етап призводив до збільшення глибини та складності, що в свою чергу призвело до значного покращення результатів у різних завданнях машинного навчання, зокрема у класифікації об'єктів на зображеннях.

У всіх цих моделях глибокого навчання спостерігається послідовне зростання глибини мережі, що дозволяє поліпшити їхні можливості у вирішенні різних завдань у сфері машинного навчання та обробки зображень.

Спостерігається тренд до послідовного збільшення глибини нейромереж. Це визначається розширенням кількості шарів та параметрів у структурі мережі, що приводить до покращення їхніх можливостей у вирішенні різноманітних завдань у галузі машинного навчання та обробки зображень.

Зі зростанням глибини нейромереж відбувається автоматичне вивчення більш складних абстракцій та представлень вхідних даних. Це дозволяє моделям ефективніше адаптуватися до різноманітних умов і вдосконалювати свою здатність до розпізнавання паттернів та вирішення складних завдань.

При збільшенні глибини мережі роль функцій активації, навчання наочних представлень та вагових коефіцієнтів стає критичною. Архітектури, такі як глибокі згорткові нейронні мережі отримують вигоду від глибокого навчання, щоб здійснювати успішне розпізнавання образів у зображеннях або робити прогнози в часових рядах.

Збільшення глибини також може призводити до виникнення викликів, таких як проблеми з перенавчанням та обчислювальною складністю. Тому вдосконалення технік регуляризації та оптимізації грають ключову роль у розвитку глибоких нейронних мереж.

Такі моделі з меншою кількістю шарів можуть бути корисними, коли обмежений обсяг доступних навчальних даних та важливо підвищити точність моделі.

Для успішної реалізації поставленої мети дослідницької роботи необхідно вивчити доступні набори даних супутникових знімків, їх характеристики та можливості попередньої обробки. Однак головний акцент полягатиме на розробці та застосуванні методів глибокого навчання для вирішення задачі ідентифікації сміттєзвалищ на зображеннях. Результати цієї роботи можуть мати велике значення для виявлення стихійних сміттєзвалищ та моніторингу дотримання екологічних стандартів.

### **Постановка задачі**

Мета кваліфікаційної роботи магістра полягає в розгляді та використанні сучасних методів глибокого навчання для ефективної ідентифікації стихійних сміттєзвалищ на супутникових знімках. Дослідження включає в себе класифікацію супутникових знімків. Для початку дослідження необхідно розробити методи для класифікації супутникових знімків на дві групи – ті, на яких видно сміттєзвалища, і ті, на яких їх відсутні. Використання глибокого навчання, такого як нейронні мережі, дозволить автоматично виділити особливості сміттєзвалищ на зображеннях і встановити їх присутність або відсутність. Класифікація різних типів відходів, яка включає в себе ідентифікацію різних типів відходів на супутникових знімках, що показують наявність сміттєзвалищ. Це може включати в себе визначення між пластиковими, металевими, органічними та іншими видами сміття. Глибоке навчання дозволить автоматизувати цей процес і визначити типи відходів на знімках. Особливістю дослідження є розробка та налаштування нейронної мережі на ідентифікацію та класифікацію стихійних сміттєзвалищ різної природи походження.

В ході дослідження та реалізації магістерської роботи необхідно вирішити наступні основні завдання:

1. Провести огляд наукової літератури та методів, пов'язаних із застосуванням глибокого навчання для ідентифікації сміттєзвалищ на супутникових знімках та класифікації відходів.

2. Здійснити вибір та збір супутникових зображень для дослідження, а також розробку методів обробки та підготовки цих даних для подальшого аналізу.

3. Розробити метод виявлення забруднень навколишнього середовища на основі супутникових зображень.

4. Провести тестування розробленого методу на відповідних супутникових зображеннях для оцінки її точності та ефективності.

Дослідження повинно включати класифікацію супутникових знімків. Використання глибокого навчання, такого як нейронні мережі, дозволить автоматично виділити особливості сміттєзвалищ на зображеннях і встановити їх присутність або відсутність. Класифікація різних типів відходів, яка включає в себе ідентифікацію різних типів відходів на супутникових знімках, що показують наявність сміттєзвалищ. Особливістю дослідження є розробка та налаштування нейронної мережі на ідентифікацію та класифікацію стихійних сміттєзвалищ різної природи походження

## **Висновки до розділу 1**

У першому розділі проведено детальний аналіз предметної області - виявлення забруднень навколишнього середовища на основі супутникових зображень. Визначено актуальність та значущість даної задачі в контексті екологічних проблем та сталого розвитку.

Досліджено основні характеристики супутникових сенсорів, що впливають на якість отримуваних зображень. Встановлено, що найбільший

вплив на подальшу класифікацію мають просторова роздільна здатність та вибір спектральних смуг в залежності від мети дослідження. Визначено, що для даного завдання найбільш придатні оптичні та радарні зображення високої роздільної здатності.

Проаналізовано переваги використання мультимодального підходу, що об'єднує дані з різних джерел та отримані різними методами. Це дозволяє моделям глибокого навчання ефективніше розпізнавати шаблони та особливості на зображеннях.

Досліджено особливості популярних архітектур нейронних мереж, зокрема згорткових нейронних мереж. Визначено доцільність їх використання для розпізнавання образів та класифікації зображень. Згорткові мережі демонструють високу ефективність у задачах розпізнавання зображень.

Сформульовано мету дослідження по розробці методу класифікації забруднень за супутниковими даними на основі глибокого навчання з використанням згорткових нейронних мереж.

Визначено основні задачі дослідження, а саме проведення аналізу літератури, підбір та підготовка даних, розробка та тестування методу класифікації.

Розділ формулює задачу та теоретичне підґрунтя для реалізації системи класифікації забруднень навколишнього середовища на основі аналізу супутникових зображень методами глибокого навчання.

Також надає необхідну теоретичну базу та формулює задачу подальших досліджень у галузі ідентифікації забруднень за супутниковими даними із застосуванням методів машинного навчання.

## **Розділ 2**

### **Метод виявлення забруднень навколишнього середовища на основі супутникових зображень**

#### **2.1 Моделі загорткової мережі з використанням супутникових знімків**

При адаптації наявних моделей загорткової мережі для аналізу супутникових знімків важливо враховувати кілька важливих аспектів. Супутникові зображення характеризуються дрібними текстурями, нюансами форм та багатою спектральною інформацією. Для того, щоб модель загорткової мережі була здатна краще впізнавати ці унікальні особливості супутникових знімків та підвищувати точність класифікації, можна внести ряд змін у різні аспекти структури моделі загорткової мережі.

Зазвичай, у галузі комп'ютерного зору, де більшість структур загорткових мереж була розроблена, вхідні дані для моделей складаються зі зображень, які мають тривимірні значення RGB. Проте супутникові знімки можуть містити інформацію не лише у видимому світлі, але й у багатьох інших спектральних діапазонах. Ця додаткова спектральна інформація більш точно описує особливості поверхні землі, тому її включення як додаткових вхідних даних може бути важливим кроком для покращення результатів моделі.

Можливість використовувати дані з різних джерел виявилася дуже корисною для досягнення високої точності при класифікації зображень поверхні землі. Об'єднуючи зображення ознак, отримані з різних наборів даних, взятих як із літака, так і з супутника, вдалося досягти значного покращення точності класифікації.

З використанням тривимірної моделі глибокого навчання та комбінуванням трьох наборів даних, кожен з яких містив десятки спектральних смуг та просторові дані як вхідні параметри, вдалося досягти дуже точності

класифікації поверхні землі. Ця комбінація підвищила результати, допомагаючи досягнути точності класифікації на рівні до 96%.

З супутникових знімків можна вилучити текстурні ознаки, які можуть бути включені в модель як додаткові параметри. До тривимірних RGB-зображень можна додати чотири текстурні ознаки: середнє значення, стандартне відхилення, консистентність та ентропію. Це значно підвищило точність класифікації та дозволило більш точно розпізнавати особливості доріг та інших об'єктів на поверхні.

Включення ознак з метаданих супутникових зображень і їх подальше використання в повністю зв'язаному шарі моделі виявилися корисними стратегіями. Додавання різних видів інформації, таких як спектральні, текстурні дані, метадані або дані з різних джерел, до вхідних даних супутникових знімків в значній мірі сприяє підвищенню точності класифікації.

Впровадження ознак з метаданих супутникових зображень та їхнє подальше використання в повністю зв'язаному шарі моделі представляють собою ефективні стратегії для покращення результатів у сфері обробки супутникових зображень. Ці стратегії дозволяють моделі отримувати більше інформації та краще розуміти контекст вхідних даних.

Додавання різних видів інформації до вхідних даних супутникових знімків, таких як спектральні характеристики, текстурні дані, метадані або інформація з різних джерел, є ефективним засобом розширення можливостей моделей. Спектральні дані можуть надати інформацію про склад поверхні, а текстурні дані можуть бути корисні для виявлення структур та об'єктів на зображеннях.

Метадані, такі як географічні координати, дата та час отримання знімків, а також інші характеристики спостережень, можуть допомагати моделі враховувати контекст і зміни в часі. Це особливо важливо для задач, пов'язаних з відстеженням змін в природних ресурсах або моніторингом природних катастроф.

Використання різноманітних джерел даних розширює розуміння моделі про оточуючий світ та сприяє підвищенню точності класифікації об'єктів на супутникових знімках. Це відкриває нові можливості для застосування супутникової зйомки в таких областях, як земельне використання, екологічний моніторинг, та управління природними ресурсами.

Модель згорткової мережі може виявити додаткові ознаки, що, в свою чергу, допоможе підвищити точність класифікації. Однак важливо враховувати, що загорткові мережі мають більше параметрів порівняно з традиційними нейронними мережами меншої глибини. Це вимагає більше навчальних даних для точного налаштування параметрів та досягнення стійкої збіжності моделі.

Згорткові мережі, які застосовуються в обробці супутникових зображень, виявляють додаткові ознаки, що сприяє значному підвищенню точності класифікації об'єктів на знімках. Їхній основний принцип полягає в використанні фільтрів для виявлення локальних особливостей у вихідних даних, таких як краї об'єктів або текстурні характеристики.

Однак важливо враховувати, що згорткові мережі мають значно більшу кількість параметрів порівняно з традиційними нейронними мережами меншої глибини. Це призводить до великої кількості вагових коефіцієнтів, які потрібно навчити, і вимагає більше обчислювальних ресурсів для тренування моделі. Більше параметрів також може виводити до ризику перенавчання, особливо при обмеженій кількості навчальних даних.

Збільшення кількості параметрів вимагає більше навчальних даних для ефективного навчання та точного налаштування моделі. Додаткові дані допомагають уникнути перенавчання та забезпечують стабільну збіжність моделі. Також, оптимізація та регуляризація важливі для підтримання ефективності згорткових мереж та запобігання їхнього перевантаження параметрами.

Усі ці аспекти важливі при розробці та вдосконаленні моделей згорткових мереж для задач класифікації супутникових зображень.

Отже, додавання додаткової інформації до моделі згорткової мережі може покращити її ефективність, але потребує обережності в налаштуванні та додаткових навчальних даних для оптимальних результатів.

На відміну від сфери комп'ютерного зору, сегмент супутникових зображень та класифікація відходів мають обмежену кількість доступних навчальних даних. Це робить важким завдання навчання глибоких моделей з великою кількістю параметрів. Щоб вирішити цю проблему, можна застосовувати методи зменшення параметрів у моделі.

Одним з таких методів є використання функції видалення. Ця функція випадковим чином вимикає певні одиниці в моделі з імовірністю, наприклад, 0,7. Це допомагає запобігти перенавчанню моделі та зменшує кількість параметрів, зберігаючи високу точність класифікації на супутникових знімках.

Для класифікації ознак також може бути використаний шар об'єднання глобальних середніх в поєднанні з функцією видалення, що значно зменшує кількість параметрів і сприяє ефективному навчанню моделі.

Класифікатор методу опорних векторів є важливим інструментом у сфері комп'ютерного зору. У дослідженнях класифікації супутникових знімків він здатний досягати високої точності. Проте, для задач класифікації відходів, де може бути високий рівень шуму, застосування звичайних зображень, а не супутникових знімків, може бути більш ефективним підходом.

Отже, в різних сферах застосування в глибокому навчанні існують методи для зменшення параметрів та покращення точності моделей, і їх вибір залежить від конкретних умов і завдань.

Додавання регуляризації до функції втрат у нейронних мережах є ефективним методом для боротьби із перенавчанням. Регуляризація сприяє зменшенню великих ваг у моделі, забезпечуючи кращу загальну придатність моделі. Цей підхід є корисним, зокрема, при класифікації рослинного покриву на супутникових знімках.

Збільшення кількості шарів у нейронних мережах може підвищити точність класифікації, але при цьому збільшується кількість параметрів, і для ефективного навчання потрібна більша кількість навчальних даних. Існує вихід із цієї ситуації, який полягає в створенні кількох незалежних моделей з різною структурою та їх подальшому об'єднанні.

Один із можливих методів - це створення ансамблю із декількох моделей, кожна з яких має свій повнозв'язаний шар. Після цього, за допомогою незваженого середнього значення різних моделей приймається рішення щодо класифікації. Така структура може давати дуже високу точність класифікації для різних класів, досягаючи 91% для деяких із них.

Отже, комбінування регуляризації, збільшення кількості шарів та ансамблювання моделей може значно покращити результати класифікації у завданнях глибокого навчання.

Існує можливість використовувати альтернативний підхід, в якому різні моделі нейронних мереж з різною структурою приймають участь у голосуванні для класифікації. Цей метод дозволяє досягти загальної точності на рівні 93%. Об'єднання різних моделей нейронних мереж в єдину структуру може бути доцільним рішенням для задач ідентифікації відходів, особливо коли обсяг навчальних даних обмежений.

Ініціалізація та оптимізація параметрів є важливими аспектами роботи будь-якої нейронної мережі. Для оптимізації параметрів часто використовуються традиційні методи оптимізації, такі як метод стохастичного градієнтного спуску.

Але ініціалізація параметрів може бути складним завданням. Ініціалізація випадковими значеннями може мати низьку ефективність навчання та вимагати великого обсягу навчальних даних. Проте цей підхід може призвести до отримання найбільш точної моделі. Інший метод - це використовувати наявну модель, яку вже навчено, і її параметри, які вже налаштовані, а потім перенавчати цю модель, щоб пристосувати її під конкретне застосування.

Такі підходи дозволяють підвищити точність та ефективність нейронних мереж у завданнях класифікації та інших сферах застосування глибокого навчання.

## **2.2 Формування даних для навчання моделей нейронної мережі**

Моделі глибокого навчання нейронних мереж значно залежать від розмаїтого набору даних для досягнення високої точності класифікації. Незважаючи на те, що існують деякі загальнодоступні набори даних для навчання, моделі часто потребують навчання для конкретної мети, для якої немає підходящого набору даних.

Проблема полягає в обмеженій кількості розмічених зображень місць скидання відходів. Незважаючи на це, існують методи для розширення наборів даних. Наприклад, створення синтетичних даних або використання методів автоматичного розширення даних.

Одним з підходів до автоматичного розширення даних є застосування простих операцій до наявних зображень у наборі даних. Це може включати обертання з певною частотою, дзеркальне відображення, перевертання зображень, випадкове переміщення або масштабування зображень. Такі методи дозволяють збільшити розмір набору даних і поліпшити загальну роботу моделі, навченої на обмеженій кількості зразків.

Інші підходи включають створення синтетичних даних, які можуть бути генеровані на основі існуючих даних. Ці методи допомагають поповнити набір даних та підвищити точність моделі. Такі стратегії є важливими для розвитку нейронних мереж у сфері супутникового зондування і класифікації.

Розширення набору даних для навчання моделей глибокого навчання нейронних мереж може бути досягнуто за допомогою різних методів. Наприклад, можна застосовувати зсуви колірних значень, розмиття і

регулювання яскравості до різних ділянок зображень на супутникових знімках, а потім використовувати ці варіації для поповнення наборів даних.

Один із методів передбачає застосування вікон змінного розміру до різних ділянок зображення та вибірку з цих вікон. Незважаючи на його простоту, цей метод може істотно розширити набір даних для навчання моделей глибокого навчання нейронних мереж.

Крім цього, можна створювати абсолютно нові дані. Наприклад, для виявлення звалищ сміття створювали синтетичні навчальні дані шляхом сортування моделей звалищ у випадкові групи та їх візуалізації на фоні супутникових знімків. Це дозволило значно збільшити обсяг навчальних даних і зберегти більшість реальних даних для оцінки моделі. Аналогічний метод використовували для візуалізації моделей на фоні супутникових знімків для створення набору даних, який зображував будівлі та описував додатковий етап використання генеративних змагальних мереж для додавання моделей до зображень.

Ці підходи є важливими для розвитку нейронних мереж у сфері супутникового зондування та класифікації.

Генеративні мережі, які призначені для модифікації зображень, виявляються найбільш ефективними у завданнях наближення зображень до реального вигляду. Проте при навчанні моделей для конкретних завдань, які стосуються зображень, часто виявляється, що зображення, створені без застосування генеративних мереж, можуть призвести до кращого поліпшення результатів. Генеративні мережі, зазвичай, краще підходять для створення перевірочних зображень, і для цього їх необхідно належним чином навчити, використовуючи значно більший набір даних.

В ситуаціях, коли доступні обмежені реальні дані, створення синтетичних даних за допомогою генеративних мереж може значно підвищити продуктивність застосування, особливо коли маємо справу з важливими особливостями і характеристиками конкретного завдання.

### **2.3 Проектування нейронної мережі з використанням контурів зворотного зв'язку**

Центральним аспектом цього проекту є можливість використання контурів зворотного зв'язку для швидкого інтегрування над прототипами. Зокрема, після впровадження параметрів, моделі можуть пройти кілька ітерацій. Після тренування моделі та оцінки її ефективності, вирішується, які параметри слід змінити, і проводиться наступна ітерація. Різниці, виявлені під час цих ітерацій, розкривають, як різні параметри впливають на результати моделей. Ітерації моделей та різноманітні результати цих ітерацій є центральними для розуміння і вдосконалення реалізації. Основна частина ідей і специфікацій спрямована на розробку підходу або методології, за допомогою яких можна виконувати кілька ітерацій моделей для аналізу впливу різних параметрів.

Головними аспектами в цьому контексті є структура набору даних, його анотування та спосіб використання даних у моделях. По-перше, розробка ідеї та специфікацій відбувається між ітераціями моделей, коли навіть невеликі зміни в коді можуть суттєво впливати на результати моделей. Після оцінювання ітерації моделі виникають нові ідеї, які втілюються в життя. Це призводить до більшої кількості експериментів, хоча підходить менш структуровано.

На етапі розробки ідеї, початкове запитання проєкт перетворюється на конкретні концепції, які відповідають на важливі питання дослідження. У випадку цього проєкт це означає, що розробляється потенційний підхід до вирішення наукових проблем. Цей підхід включає в себе визначення того, які глибокі моделі підходять для даної реалізації, а також можливі методи навчання цих моделей для вирішення висунутих завдань.

Завершальною стадією розробки ідеї може бути ітеративний процес творчого мислення, що включає у себе креативні ідеї на базі технології і формулювання вимог.



Рисунок 2.1 – Етапи розробки методу виявлення забруднень навколишнього середовища на основі супутникових зображень

У цьому проєкт дослідження наукових джерел відіграє ключову роль. Наукові джерела, що стосуються аналогічних завдань, а також звіти про останні досягнення в галузі, допомагають вибирати потенційні глибокі моделі навчання та визначати оптимальні методи навчання. Розглядаються різні структури нейронних мереж і методи їх навчання, а також використовуються аспекти та ідеї з аналогічних проєкт з класифікації.

У специфікації подальших вимог цей підхід стає ще більш конкретним та деталізованим. На основі літературних джерел, потреб замовника та впроваджуваних ідей формується чіткий та структурований план. Цей план виступає основою для подальшої реалізації проєкту на більш пізніх стадіях.

Реалізація ідеї включає в себе кілька важливих компонентів. Перший крок полягає в підготовці навчальних даних та їх попередній обробці, включаючи процес маркування, розділення на навчальні та тестові набори даних, а також форматування даних для використання.

Далі важливим етапом є реалізація вибраної моделі нейронної мережі, навчання цієї моделі та тестування її на навчальних даних.

Заключним етапом є процес оцінювання результатів. На цьому етапі представляються та оцінюються досягнуті результати, використовуючи відповідні метрики оцінки. Отримані висновки та результати обговорюються під час ітерацій між етапами проєкту.

На завершення проєкт висновки формулюються на основі отриманих результатів і обговорень між ітераціями, включаючи оцінку ефективності розробленої моделі та її відповідність поставленим завданням.

Для надання проєкту структурованості, його виконання поділяється на два основних етапи. Початковий етап передбачає проведення простої бінарної класифікації для оцінки можливості використання запропонованих технологій у вирішенні завдання класифікації відходів. Для цієї мети моделі навчаються та тестуються на здатність класифікувати два типи зображень. Перший тип - це зображення, на яких звалище можна чітко розпізнати, а другий - зображення, на

яких звалище візуально нерозрізниме. Результати цієї основної бінарної класифікації визначають, наскільки ефективно моделі, які використовуються, сприймають текстурні, формові та розмірні ознаки сміттєзвалищ.

Після завершення цього етапу виконується більш складна класифікація, на якому моделі глибокого навчання навчаються та оцінюються щодо їхньої здатності класифікувати різні види відходів. Ця більш складна задача вимагає використання іншого методу порівняно з бінарною класифікацією сміттєзвалищ.

## **2.4 Класифікація на основі бінарного підходу**

Як вже зазначено раніше, першим кроком буде спроба використовувати бінарну класифікацію для розділення об'єктів на два класи звалище та без звалища. Цей процес передбачає послідовність ітерацій, під час яких використовуємо різні моделі з метою досягнення максимальної точності. Ця точність дозволить впевнено перейти до наступного етапу - більш складної задачі класифікації.

Для навчання нейронної мережі необхідно мати значний обсяг навчальних і тестових даних. У сценаріях, подібних до класифікації відходів, відсутність таких наборів даних може обмежити можливості. Навіть при наявності великої кількості супутникових знімків, перед тим, як зможемо використовувати їх для навчання нейронної мережі, необхідно провести правильне маркування. Збір таких даних і їх маркування часто є найбільш дорогим та довгим етапом дослідження.

Таким чином, збирання та маркування даних зображень супутникових знімків, які містять інформацію про наявність сміття або звалищ, є необхідною передумовою для подальшого успішного розвитку дослідження та використання нейронних мереж у цьому контексті.

У рамках даного проєкт було зібрано дані, пов'язані із стихійним накопиченням відходів, а також набір даних без попереднього маркування. На

рисунку 2.2 наведено приклад зображення місця стихійного накопичення відходів. Для отримання таких зображень було використано програму Google Earth. На жаль, не всі отримані зображення гарантовано містять інформацію про наявність звалищ. Тому необхідно виконати ручну анотацію цих зображень.

Загалом, набір даних включає в себе понад 10 000 зображень, які є результатом цього процесу. Однак, важливо врахувати, що не всі з цих зображень містять інформацію про наявність стихійних сміттєзвалищ. Тому наступним кроком є проведення ручної анотації, щоб відзначити та класифікувати зображення, які містять звалища, і ті, що їх не мають. Цей етап є важливим для створення точних та надійних наборів даних для навчання моделей у майбутньому.




Рисунок 2.2 – Зображення із місцями скидання відходів

Зображення, отримані за допомогою системи Google Earth, характеризуються високою просторовою роздільною здатністю, приблизно 0,30 м на піксель. Ця висока роздільна здатність є необхідною для успішного розпізнавання відходів на супутникових знімках, оскільки зазвичай розмір окремих відходів, що викидаються, не перевищує одного квадратного метра.

Однак важливо враховувати, що така висока роздільна здатність призводить до створення зображень з великою кількістю пікселів, які можуть складати 1000 на 1000 пікселів.

Недоліком цього підходу є значне збільшення обчислювального обсягу обробки зображень. Однак більшість моделей глибокого навчання, зокрема згорткові нейронні мережі, зазвичай працюють з обмеженими розмірами зображень, які зазвичай становлять 512 на 512 пікселів. Отже, необхідно вирішити проблему обрізання зображень до відповідного розміру. Це досягається за допомогою автоматичної пакетної операції, під час якої зображення обрізаються до розміру 512x512 пікселів, залишаючи центральну частину, як продемонстровано на рисунку 2.3.



Рисунок 2.3 – Зображення зменшене та розмічене

Причина обрізки зображень по центру полягає в тому, що координати зафіксованого місця скидання розташовані в центрі кожного знятого зображення. Такий підхід забезпечує те, що місце скидання не буде обрізане під час обробки зображень. Додатково, це дозволяє отримати більше зображень, на яких не видно скидання, шляхом обрізки кутів зображень, якщо потрібно збалансувати класи. Оскільки місця скидання розташовані в центрі зображень, зображення у кутах міститимуть мінімум інформації про скидання.

Додатково, обрізка зображень спрощує процес ручного анотування, оскільки зменшує загальну площу захоплення, що відображається на зображенні. Це в свою чергу зменшує обсяг ручного пошуку звалищ на зображеннях, полегшуючи процес анотування.

Процес ручного анотування включає в себе огляд кожного зображення та визначення наявності або відсутності звалища на ньому. Також, деякі зображення можуть бути повністю відфільтровані, якщо область обрізки містить хмарність або інші артефакти, що роблять їх непридатними для подальшого використання. Оскільки обсяг анотації великий, а ручне анотування ресурсомісткий процес, планується здійснювати анотування протягом першої половини проєкту, паралельно з проведенням перших ітерацій моделі.

Перевагою цього підходу є можливість спостерігати, як зростаючий обсяг навчальних даних впливає на результати роботи моделей. Такий аналіз є важливим у контексті глибокого навчання, оскільки дозволяє оцінювати, наскільки моделі можуть ефективно узагальнювати на нові дані.

Особливість полягає в можливості систематично аналізувати вплив зростаючого обсягу навчальних даних на результати роботи моделей. Такий аналіз стає ключовим в контексті глибокого навчання, де важливо визначити, наскільки моделі здатні ефективно узагальнювати на нові дані.

Збільшення обсягу навчальних даних може призвести до кількох важливих висновків. По-перше, відзначається покращення у здатності моделі виявляти складні закономірності в даних, що підвищує її здатність до точної

класифікації. По-друге, аналіз впливу різноманітності та розмірів даних може допомогти визначити момент, коли подальше збільшення обсягу даних може припинити приносити значну користь.

Цей підхід також дозволяє визначити можливість виникнення перенавчання, особливо якщо приріст точності на навчальних даних не супроводжується аналогічним покращенням на тестових або нових даних. Дослідження впливу розмірів вибірки на різних етапах навчання може допомогти визначити оптимальні обсяги даних для досягнення високої точності та узагальнення.

Загалом, аналіз залежності результатів від обсягу навчальних даних відіграє важливу роль у вдосконаленні та налаштуванні глибоких моделей, роблячи їх більш стійкими та ефективними в різних умовах застосування.

Після завершення анотування необхідної кількості зображень, набір даних розподіляється на дві частини навчання і тестування моделей. Такий розділ на навчальні та тестові дані є стандартним підходом у проєктах глибокого навчання і дозволяє ефективно оцінювати моделі після їхнього навчання. Тестові дані зберігаються окремо від тренувальних і використовуються для оцінки роботи моделей лише після завершення навчання. Це дозволяє переконатися, наскільки добре модель може працювати на абсолютно нових даних, що є важливою характеристикою її роботи.

У цьому проєкті обрано стандартне відсоткове співвідношення, де 70% даних використовується для навчання, а 30% - для тестування моделей. Такий розподіл є загальноприйнятим і використовується в багатьох дослідженнях для навчання та оцінки моделей глибокого навчання.

## **2.5 Ітерації моделі та порівняння ефективності моделей**

Після анотування початкової кількості зображень запускаються різні моделі в однакових умовах з однаковим обсягом даних для порівняння їх

ефективності. Для цього вибрано три популярні моделі глибокого навчання: ResNet50, ResNet100 і VGG16. Вибір цих моделей обґрунтовується їхньою популярністю та ефективністю, підтвердженою проведеними дослідженнями в галузі машинного зору.

Кожна з цих моделей має унікальну архітектуру, що дозволяє порівнювати їхні різні структури та характеристики. Після першої ітерації вибирається модель, яка продемонструвала найкращі результати. Ця ефективність оцінюється за допомогою таких метрик, як точність, F-score та матриця заплутаності.

Під час подальших ітерацій будуть внесені зміни в різні параметри, такі як розмір набору даних, балансування класів та тривалість навчання. Це дозволить покращити результати моделі та забезпечити її оптимальну роботу в нових умовах.

Реалізація моделей виконується з використанням мови програмування Python та бібліотек Tensorflow і Keras, які є широко використовуваними інструментами у галузі глибокого навчання.

Після проведення досліджень була обрана модель, яка показала найкращі результати. Ця модель буде використовуватися для подальших ітерацій та оптимізації. Також, буде проведено оцінку моделі з метою порівняння її з обраною моделлю.

Вибір відповідної моделі обумовлений меншим розміром навчальних і тестових даних, для яких необхідно оптимізувати структуру моделі. Планується провести кілька ітерацій навчання та оцінювання моделей, вносячи зміни в параметри між ними. Це дозволить оцінити вплив параметрів на продуктивність моделей.

У подальших етапах також планується використання методів доповнення даних. Ці методи розширення даних можуть стати корисними в умовах обмеженого обсягу наявних даних та допоможуть покращити результати моделей.

Моделі будуть реалізовані за допомогою мови програмування Python та використання скриптів Tensorflow і Keras, що є популярними інструментами для глибокого навчання в галузі машинного зору.

## 2.6 Класифікація видів відходів

Після успішної бінарної класифікації відходів, наступний етап проекту спрямований на дослідження ефективності глибоких моделей навчання для класифікації різних типів відходів. Застосовується схожий підхід до методики, що використовувалася для класифікації сміттєзвалище та не сміттєзвалище, але з іншим набором даних та параметрами, які змінюються між ітераціями.

Для спрощення завдання класифікації спочатку моделі навчаються та тестуються на розрізненні двох типів відходів. Це дозволяє перевірити доцільність використання цих моделей для складного завдання класифікації та вдосконалити їх роботу. У разі наявності додаткового часу та ресурсів, планується розширити класифікацію на більшу кількість типів матеріалів.

Цей підхід дозволяє послідовно вивчати та оптимізувати моделі, починаючи з менш складної задачі та поступово розширюючи їхню функціональність.

Для вирішення цього завдання класифікації було використано інший набір даних. Це виправдано тим, що для навчання моделей розпізнавання різних типів відходів потрібні зображення, які правильно позначені різними категоріями відходів і підтверджені відповідними даними. Попередній набір даних, який був зібраний та анотований, не мав такої деталізації та інформації про типи матеріалів на сміттєзвалищах. Тому був обраний набір даних AerialWaste, оскільки підмножина цього набору має багатокласову анотацію.

У цьому наборі даних було виявлено багато унікальних зображень, які були анотовані різними типами відходів і типами сховищ, при цьому деякі з них мали кілька категорій. Список різних категорій та кількість зображень з цими

мітками наведено в таблиці 2.1. Важливо відзначити, що цей список може містити дублікати між категоріями. Також слід врахувати, що набір даних вже поділений на навчальний і тестовий, але оскільки спочатку проводиться класифікація між двома основними класами відходів, ці категорії можна об'єднати в два загальні класи, які відображають певні типи відходів.

Таблиця 2.1 – Розширені мітки набору даних

<b>Види сміття</b>	<b>Усього зображень</b>	<b>Зображення для тренування</b>	<b>Тестові зображення</b>
Каміння	320	250	70
Великогабаритні вироби	310	260	50
Дерева	180	140	40
Пластмаси	135	110	25
Транспортні засоби	60	30	30
Шини	50	35	15
Побутова техніка	28	22	6
Папір	30	24	6
Зоотехнічні відходи	22	18	4
Фрезерування асфальту	14	11	3
Скло	10	7	3
Купи не розмежовані	480	380	100
Повний контейнер	180	120	60
Великі пакети	60	37	23
Розмежовані купи	80	45	35
Органічні відходи	100	80	20
Відходи хімічної промисловості	80	65	15
Відходи електроніки	70	55	15

## Продовження таблиці 2.1

Мастила	40	35	5
Відходи від будівництва	120	100	20
Відходи харчової промисловості	90	75	15
Текстильні відходи	50	40	10
Відходи від сільського господарства	70	60	10

Цей набір даних може слугувати як навчальні дані для моделей. Для перевірки ефективності використання цієї технології визначено використання анотованого набору даних. Важливо відзначити, що для деяких місць звалищ не має наявних даних щодо типів відходів. Це вказує на необхідність вдосконалення методів анотації та збору даних для більш повного охоплення різноманітності відходів на цих місцях.

З цим викликом пов'язано необхідність розробки нових стратегій збору даних або використання альтернативних джерел інформації, таких як обробка зображень з дронів або використання аудіо- та відеоаналізу для визначення типів відходів. Це допоможе покращити роботу моделі в умовах обмеженого доступу до анотованих даних на деяких звалищах. При цьому важливо забезпечити узгодженість та точність збору даних для об'єктивної оцінки ефективності технології на різних місцях.

Однак можливо вручну створити невеликий набір зображень для двох основних класів, використовуючи контекстні підказки, які можна виділити зі зображень. Наприклад, звалище можна визнати як будівельне сміття, якщо воно розташоване поруч з реальним будівельним майданчиком. Цей процес ручної анотації, як і будь-який інший, є складним та вимагає великих зусиль. Проте для тестування технології достатньо невеликого обсягу даних.

## Висновки до розділу 2

У цьому розділі були проаналізовані та порівняні різні моделі, і після попередніх досліджень була обрана модель, яка показала найкращі результати. Далі було вирішено використовувати модель для оцінки їх ефективності. Вибір такого підходу обумовлено меншим розміром навчальної та тестової вибірок, для яких потрібно оптимізувати більш широку структуру моделей. Проведено кілька ітерацій навчання і оцінювання моделей, включаючи налаштування параметрів між ними.

В ході дослідження враховувалася зміна часу навчання, а також використання методів доповнення даних. Використані методи розширення даних мають потенціал дати хороші результати, особливо з урахуванням обмежень, пов'язаних із обмеженим обсягом даних. Важливо враховувати розмір навчального набору даних і оптимально налаштувати параметри моделей для досягнення найкращих результатів. Модифікація параметрів навчання і використання методів доповнення даних можуть покращити продуктивність моделей.

Описаний метод надає структурований підхід до реалізації проекту з використанням нейронних мереж для класифікації відходів. Метод містить послідовність розроблених етапів. Етапи включають підготовку навчальних даних, реалізацію моделі, тестування та оцінювання результатів. Велика увага приділяється обробці даних, вибору та навчанню моделі. Завершальний етап включає оцінку результатів та обговорення. Проєкт поділяється на бінарну та складну класифікацію відходів, з можливістю ітерацій та корекцій. Висновки формулюються на основі отриманих результатів, оцінюється ефективність розробленої моделі. Загалом, метод сприяє систематичному та виконанню поставлених завдань, покращенню якості моделі та досягненню ефективних результатів.

## Розділ 3

### Інформаційна система виявлення забруднень навколишнього середовища на основі супутникових зображень

#### 3.1 Попереднє оброблення даних зображення

Перший етап реалізації проєкту глибокого навчання включає в себе попередню обробку набору даних. У зв'язку з великою кількістю зображень у цьому наборі даних, роботу з попередньою обробкою було розподілено на роботу з набором даних та розробку моделі.

Після поділу кількості зображень, здійснено попередню обробку. Спочатку зображення були обрізані до розміру 512x512 пікселів, використовуючи автоматичну пакетну обрізку. Це дозволило застосовувати однакові зміни до численних зображень автоматично.

З огляду на велику кількість зображень і значний розмір файлів зображень, завантажували їх частинами. Кожна порція зображень обрізалася перед завантаженням наступної, враховуючи доступний обсяг місця.

Після завантаження та обрізки зображень, застосовано етап анотування. На рисунку 3.1 можна побачити приклад зображення, на якому видно розробку кар'єру, яка може бути ідентифікована як сміття.

Анотування зображень передбачало візуальний огляд кожного з них для визначення наявності або відсутності видимого скидання відходів. Деякі знімки було важко анотувати через рельєф місцевості або мінімальні відмінності між знімками об'єктами одного і того ж місця. Всі зображення були впорядковані в два файли, кожен з яких був анотований відповідно до результатів огляду.



Рисунок 3.1 – Зображення, на якому видно розробку кар’єру, що може ідентифікуватись як сміття

Окрім анотування зображень, на яких видно сміття і відсутність сміття, також було видалено зображення, які не підходили для використання в навчанні та оцінюванні моделей через такі причини, як хмарність, дуже темні зображення або наявність інших артефактів. Це призвело до скорочення обсягу набору даних. Оскільки залишалася значна кількість зображень, які потребували анотування, було використано методи для спрощення процесу сортування цих зображень після візуального аналізу.

Для прискорення завантаження та перегляду зображень використовувався метод швидкого завантаження, що дозволяв швидко переглядати набір даних без затримок під час завантаження. Загалом, процес ручної анотації зайняв приблизно місяць для всього набору даних. Протягом цього часу також відбувалася ітеративне навчання моделей на різних обсягах набору даних.

Після завершення повної анотації набір даних складався з приблизно 7000 зображень в класі звалище і приблизно 3000 зображень в класі без звалища. Деякі зображення не несли інформації та можуть бути визнані як викиди, як показано на рисунку 3.2. Також існують зображення, які є реальними, але не містять загальної інформації рисунок 3.3.




Рисунок 3.2 – Приклад зображення, як є викидами та непридатними для використання

Зважаючи на велику різницю у кількості знімків, на яких видно або не видно звалища, було створено нові зображення для додавання до класу без звалища. Для цього використовувалися отримані повнорозмірні супутникові знімки, з яких вирізали ділянки розміром 512x512 пікселів з кутів знімків, і цей процес був автоматизований у партіях. Оскільки координати місць сміття

розташовані в центрі знімків, ділянки, які вирізалися з кутів, гарантовано не містили зображень сміття.



Рисунок 3.3 – Приклад зображення, які є реальними зображеннями але не несуть корисної інформації

Корпус даних складається з 10 434 зображень, які були отримані з трьох різних джерел AGEA Orthophotos з приблизним розширенням 20 см на піксель, WorldView-3 з приблизним розширенням 30 см на піксель і GoogleEarth з приблизним розширенням 50 см на піксель. З цього набору даних 3478

зображень представляють собою позитивні приклади, які відображають місця, віднесені до підозрілих, та 6956 зображень є негативними прикладами. Більшість позитивних прикладів мають метадані, які включають інформацію про тип об'єкта на зображенні. Зазначено, що підмножина з 715 прикладів має анотації класів сміттєвих об'єктів, видимих на зображеннях, і ці об'єкти були вибрані із 22 різних категорій. Крім того, 169 зображень мають сегментаційні маски, які визначають межі об'єктів для 9 класів сміття, деталі наведено в таблиці 3.1.

Таблиця 3.1 – Дані для аналізу

№	Джерело	Роздільна здатність	Кількість позитивних	Кількість негативних	Метадані	Кількість об'єктів	Кількість масок сегментації
1	AGEA	20 см	2486	5799	Так	604	169
2	WorldView-3	30 см	1578	4688	Так	504	140
3	GoogleEarth	50 см	3251	6105	Так	523	121

Ця таблиця містить інформацію про зображення, включаючи джерело, роздільну здатність, тип позитивний або негативний, метадані, кількість об'єктів, кількість масок сегментації.

Розподіл даних за джерелами походження подано на діаграмі рисунок 3.4.

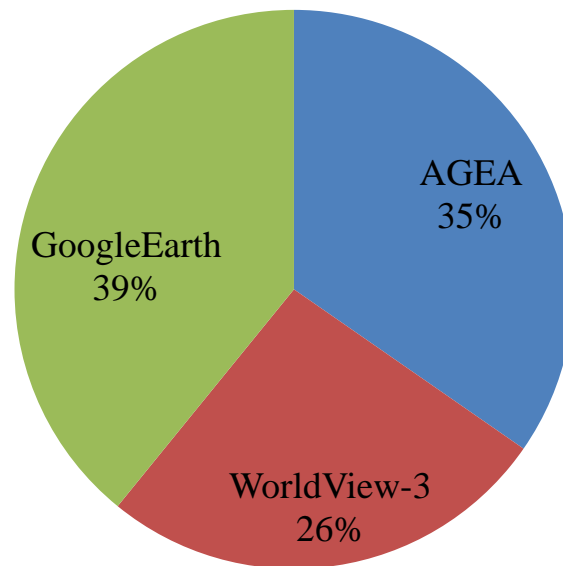


Рисунок 3.4 – Розподіл даних за джерелами

Після анотування певної кількості зображень на кожній ітерації проєкту, набір даних піддається поділу на навчальні та тестові частини. Цей процес поділу було реалізовано за допомогою мови програмування Python з використанням простої функції, яка забезпечує послідовність розділу даних. Використовуючи цей підхід, забезпечено однаковий розділ даних на кожній ітерації, що дозволяє знизити розкид між різними моделями та забезпечити консистентність результатів.

### 3.2 Реалізація та аналіз моделей

Навчання і оцінювання різних моделей глибокого навчання виконується через кілька ітерацій. Позитивною особливістю цього проєкту є те, що код різних моделей та ітерацій майже ідентичний. Реалізація моделей використовує мову програмування Python, і завдяки бібліотеці TensorFlow з додатковим використанням Keras легко завантажувати моделі. Це спрощує процес створення різних моделей, оскільки не потрібно писати код з нуля для кожної моделі.

Крім того, ці бібліотеки дозволяють імпортувати попередньо розподілення ваги, що сприяє прискоренню процесу збіжності моделі. Це особливо корисно, коли набір даних обмежений. Один з прикладів реалізації моделі подано у псевдокоді, і подібні сценарії можуть бути використані для інших моделей.

Слід відзначити, що фінальний класифікаційний шар має тільки один вузол і використовує сигмоїдальну функцію активації, оскільки виконується бінарна класифікація. Також під час компіляції моделі можна вибрати бажану метрику оцінки, таку як *accuracy*, *precision*, *recall* та інші, а також компоненти для матриці помилок, які включають істинно позитивні, хибно позитивні, істинно негативні та хибно негативні результати.

Крім того, розмір партії може бути змінений у коді, і цей параметр визначає кількість зображень, які одночасно подаються в модель під час навчання. Цей параметр дозволяє регулювати розмір партії відповідно до обраної моделі та обчислювальних ресурсів.

#### Алгоритм 1.

1. Функція підготувати\_набір\_даних.
2. Збереження шляхів до каталогів навчальних і тестових даних у змінних (*train\_dir* та *test\_dir*).
3. Створення порожнього списку *train\_data* для навчальних даних та *test\_data* для тестових даних.
4. Проходження через файли в каталозі *train\_dir*.
5. Для кожного файлу.
6. Зчитування та підготовка даних з файлу, наприклад, зображення та мітки.
7. Додавання даних до списку *train\_data*.
8. Проходження через файли в каталозі *test\_dir*:
9. Для кожного файлу.

10. Зчитування та підготовка даних з файлу, наприклад, зображення та мітки.
11. Додавання даних до списку `test_data`.
12. Повернення `train_data` та `test_data` як результат функції `підготувати_набір_даних`.
13. Змінна модель для збереження моделі нейронної мережі.
14. Виклик функції підготовки набору даних для підготовки навчальних та тестових даних.
15. Отримання навчальних даних.
16. Отримання навчальних даних, які вже можуть бути завантажені в пам'ять, щоб звільнити ресурси.
17. Отримання тестових даних.
18. Отримання тестових даних, які можуть бути завантажені в пам'ять, щоб звільнити ресурси.
19. Видалити останній шар моделі, наприклад, останній щільний зв'язок.
20. Додати новий шар зі щільним зв'язком до моделі, наприклад, з 128 нейронами та функцією активації, наприклад, ReLU.
21. Додати фінальний шар класифікації до моделі з відповідною кількістю виходів, кількість класів та функцією активації, наприклад, softmax.
22. Скласти модель з обраними метриками оцінки, оптимізатором та функцією втрати.

Для задоволення високих обчислювальних потреб, необхідних для виконання підготовлених скриптів, була використана відеокарта RTX 3070 Ti, яка надає значно більше обчислювальних потужностей. Це стало ключовим чинником для успішної обробки великого обсягу обчислень. Навіть за наявності доступу до таких потужних ресурсів навчання та оцінювання деяких моделей займали понад 24 години. Це свідчить про те, наскільки обчислювально

вимогливими можуть бути завдання для моделей глибокого навчання цього типу.

Для досягнення успішних результатів у проєкті використовувались великі обчислювальні ресурси, зокрема, використано 6144 ядра CUDA відеокарти. Внаслідок кількох ітерацій роботи над проєктом виникла необхідність у використанні ще потужніших графічних процесорів через обмеження пам'яті, яке виникало під час обробки великих наборів даних.

Проєкт включає різні ітерації навчання та оцінювання моделей. Перша ітерація більше схожа на тестовий запуск, призначений для перевірки правильності реалізації. На цьому етапі використовувалася модель ResNet50, а набір даних містив лише 2000 зображень.

Після успішного завершення тесту виконано порівняння трьох попередньо обраних моделей CNN: ResNet50, ResNet100 і VGG16. Ці моделі навчалися та оцінювалися на розширеному наборі даних, який тепер містить 10 000 зображень. Після цього для подальших ітерацій використовувалася модель, яка продемонструвала найкращі результати, а саме модель ResNet100.

На наступних ітераціях модель ResNet100 використовувалася для навчання та оцінювання на різних варіантах набору даних. Перша з цих ітерацій включала параметр вага класу, який додавався до моделі для навчання. Цей параметр дозволяв надавати більшу вагу класу з меншою кількістю зображень, з метою балансування впливу класів на навчання моделі.

Оскільки додаткові зображення без звалищ ще не були згенеровані, додавання цього параметра могло покращити продуктивність моделі. Для першої з цих двох ітерацій різниця між кількістю зображень була апроксимована, а для другої ітерації вона була обчислена точно. Наступна ітерація включала ще більше зображень, щоб розширити набір даних до 5000 зображень, що охоплює весь анотований набір даних.

У наступній ітерації знову використовується лише модель ResNet100. В цей раз додаються додаткові зображення без звалищ, що збільшує загальну

кількість зображень до 20 000. Крім того, кількість епох збільшено до 5, порівняно з 1, яка була встановлена за замовчуванням в попередніх ітераціях. Кількість епох визначає, скільки разів модель буде проходити через весь набір даних під час навчання. Загалом, більша кількість епох інтуїтивно повинна покращити продуктивність моделі.

На передостанній ітерації кількість епох знову збільшується, цього разу до 8. У цей раз всі три моделі знову навчаються та оцінюються. Модель, яка показує найкращі результати, проходить останню ітерацію з подальшим збільшенням кількості епох до 10. Це дозволяє визначити, чи можливе значне поліпшення ефективності на останній стадії, або ж модель досягла своєї оптимальної точки.

Навчання та оцінювання моделей.

Крок 1: Тестування на невеликому наборі даних, 2000 зображень

- Використання моделі ResNet50 для перевірки правильності реалізації.
- Набір даних складається лише з 2000 зображень.

Крок 2: Порівняння трьох моделей ResNet50, ResNet100, VGG16.

– Навчання та оцінка трьох моделей ResNet50, ResNet100, VGG16 на наборі даних розміром 10 000 зображень.

Крок 3: Вибір найкращої моделі для подальших ітерацій.

– Модель ResNet100 обрана на основі кращих результатів попередньої ітерації.

Крок 4: Додавання параметра вага класу до моделі.

– Додавання параметра вага класу до моделі ResNet100 для балансування класів з різною кількістю зображень.

– Різниця у кількості зображень апроксимується на цій ітерації.

Крок 5: Друга ітерація з параметром вага класу

– Додаткова ітерація з встановленим параметром вага класу для подальшого балансування навчання моделі.

– Різниця у кількості зображень обчислюється точно на цій ітерації.

Крок 6: Збільшення розміру набору даних до 5000 зображень.

– Збільшення розміру набору даних до 5000 зображень, включаючи всі доступні анотовані дані.

– Використана лише модель ResNet100.

Крок 7: Додавання зображень без звалищ.

– До набору даних додаються додаткові зображення без звалищ.

– Загальний розмір набору даних стає 20 000 зображень.

Крок 8: Збільшення кількості епох навчання до 5.

– Кількість епох збільшується до 5, замість 1, як на попередніх ітераціях.

Крок 9: Збільшення кількості епох навчання до 8.

– Кількість епох знову збільшується, на цей раз до 8, для подальшого покращення результатів.

Крок 10: Збільшення кількості епох навчання до 10.

– Остання ітерація включає збільшення кількості епох навчання до 10, щоб перевірити, чи може модель досягти подальшого покращення ефективності.

Ці кроки демонструють послідовність дій, які були виконані під час кожної ітерації для покращення моделі та її результатів оцінювання.

Було вирішено навчити та перевірити моделі для класифікації між двома класами типів відходів, щоб спростити завдання класифікації. Для переконання у життєздатності ручного анотування цих двох класів з попереднього набору даних були обрані два різні типи відпрацьованих матеріалів: будівельне сміття та звичайне сміття. Ці класи мають текстурні та контекстуальні особливості, які сильно відрізняються один від одного, що дозволяє спростити ручне анотування і робить завдання глибокого навчання менш складним.

Подібно до попередньої частини проекту, реалізація цієї частини складається з попереднього оброблення даних та створення моделі. Ці процеси відбуваються паралельно, і відмінності між ітераціями будуть розглянуті.

### 3.3 Попереднє опрацювання масиву даних

Як було зазначено раніше, для навчального набору даних був використаний набір даних AerialWaste. Цей набір даних містить підмножину зображень, які були класифіковані за різними категоріями відходів, і для відповідності цим категоріям будівельне сміття і звичайне сміття були вибрані відповідні категорії. Слід відзначити, що деякі зображення мали кілька міток і, відповідно, були дубльовані між категоріями, де відповідно наведено обсяг зображень із видаленими дублікатами. Окрім того, набір даних містить зображення, отримані за допомогою системи Google Earth, супутникового супутника WorldView-3 і під час аерофотозйомки Agea. З огляду на те, що зображення з Agea є аерофотозйомкою і мають більш високу просторову роздільну здатність, ніж тестові зображення, їх також було видалено з набору даних.

Оскільки для тестування моделей використовується оброблений набір даних, для навчання використовуються об'єднані дані, що служать як навчальний, так і тестовий набори даних. Крім того, всі зображення були обрізані по центру до розміру 512 на 512 пікселів.

Для тестового набору даних у завданні класифікації типів відходів використовується той самий набір даних з ручною анотацією, який вже був використаний. Оскільки були обрані класи з різних категорій відходів, було необхідно провести ручну анотацію невеликої кількості зображень для обох класів. Вибрані класи для цієї задачі класифікації повинні бути впізнаваними за контекстом та ландшафтом, представленим на зображеннях. Наприклад, звичайне сміття може бути розпізнане за міськими околицями та невеликими купами сміття, тоді як будівельне сміття може бути впізнане, якщо на сміттєзвалищі є будівельний майданчик.

Аналогічно до попереднього процесу анотування, ручний відбір був важким завданням. У підсумку, з вибірки зображень із видимими

сміттєзвалищами було відібрано 50 окремих зображень, із них 25 належать до класу будівельне сміття, а інші 25 - до класу звичайне сміття. На рисунках 3.5 і 3.6 наведено приклади з кожного класу.



Рисунок 3.5 – Зображення будівельного сміття

Додатковим контекстним ключем до розпізнавання будівництва є використання часових рядів. Наприклад, якщо будівля присутня на одному знімку, але відсутня на іншому знімку, зробленому в тому ж місці, але в інший

час, це може свідчити про те, що в проміжку між знімками будівля була збудована або знесена, і, отже, це свідчить про будівництво.



Рисунок 3.6 – Зображення сміття: пластику, палети, скло та інше

### 3.4 Адаптація моделі до набору даних

Підхід, використаний в цій частині проекту, в багатьох аспектах співпадає з попереднім. Тому сценарій Python, який був використаний в попередній

частині проекту, може бути легко адаптований для використання в новому завданні класифікації. Проте набір даних, який використовується як навчальні дані, має свій власний формат і вимагає використання певних вбудованих утиліт Python для фільтрації та вилучення зображень.

Для адаптації до цього на початок скрипта додано додатковий код. Подання коду у вигляді псевдокоду наведено в Алгоритм 2.

#### Алгоритм 2.

Крок 1. Імпортувати утиліту набору даних.

Крок 2. Завантажити список навчальних зображень з бажаними категоріями будівельні відходи за допомогою відповідної утиліти.

Крок 3. Завантажити список тестових зображень з бажаними категоріями будівельні відходи за допомогою відповідної утиліти.

Крок 4. Створити список навчальних зображень будівельне сміття з обох списків навчальних і тестових зображень, які належать до категорії будівельні відходи.

Крок 5. Завантажити список навчальних зображень з потрібними категоріями сміття за допомогою відповідної утиліти.

Крок 6. Завантажити список тестових зображень з потрібними категоріями сміття за допомогою відповідної утиліти.

Крок 7. Створити список навчальних зображень сміття з обох списків навчальних і тестових зображень, які належать до категорії сміття.

Крок 8. Підготувати навчальні дані для категорії будівельні відходи шляхом використання функції підготувати набір даних для списку навчальних зображень будівельні відходи.

Крок 9. Підготувати навчальні дані для категорії сміття шляхом використання функції підготувати набір даних для списку навчальних зображень сміття.

Крок 10. Об'єднати навчальні дані для категорій будівельні відходи та сміття, щоб створити навчальний набір даних, який є комбінацією обох категорій.

У цьому завданні класифікації, деякі ітерації моделей включають в себе використання методів розширення даних. Це досягається завдяки бібліотекам TensorFlow і Keras, які легко інтегруються у наявний сценарій. Для цього використовується генератор даних, який може бути доданий одним рядком коду перед початком навчання та оцінюванням моделі. Цей рядок створює генератор даних з вибраними методами розширення даних, який потім використовується як один з параметрів. Ітерації у цій частині проєкту виконуються в системі обчислень, використовуючи той самий базовий сценарій завдання.

Оскільки модель ResNet100 продемонструвала найвищу ефективність в попередньому завданні класифікації, вона вибрана для використання у більшості ітерацій дослідження. Проте, для забезпечення повноти та різноманітності оцінки також розглядаються і дві інші моделі. Різноманітність ітерацій визначається параметрами, такими як кількість епох, розмір пакета для навчання та методи доповнення даних. Це дозволяє систематично оцінювати вплив різних конфігурацій на результати та визначати оптимальні налаштування для покращення загальної ефективності моделі.

У кожній ітерації варіюються параметри, такі як кількість епох, для налагодження тривалості навчання та врахування можливих перенавчань чи недонавчань. Розмір пакета визначає, скільки прикладів використовується для кожного кроку навчання, що впливає на швидкість навчання та обсяг використовуваної пам'яті. Методи доповнення даних включають в себе техніки, які розширюють навчальний набір за рахунок випадкових трансформацій та обрізання зображень, що допомагає уникнути перенавчання та поліпшує узагальнення моделі.

Такий підхід дозволяє глибше розуміти реакцію моделі на різні умови навчання, підвищуючи стійкість та узагальнення результатів. Аналізуючи вплив різних параметрів, можна визначити оптимальні умови для навчання моделі та максимізувати її точність та стійкість на нових даних.

У першій ітерації була використана модель ResNet100 з 10 епохами, але це було зроблено до відфільтрування зображень Agea. Другу ітерацію провели з такими ж параметрами, але вже після відфільтрування зображень Agea. Для третьої ітерації кількість епох було збільшено до 15 з метою підвищення ефективності моделі. У наступних ітераціях, за допомогою моделі ResNet100, використовували методи збільшення обсягу даних, спрямовані на подолання обмежень, пов'язаних із розміром набору даних.

Методи розширення даних включали в себе обертання зображень, а також перевертання їх по вертикалі і горизонталі. Ці методи були обрані, оскільки вони м'яко змінюють зображення і не впливають на текстурні особливості, що можуть бути присутніми. Це дало можливість подальшого розширення методів розширення даних. Цю ітерацію було повторено, але вже з кількістю епох, збільшеною до 20.

Це дозволило прямо порівняти широку структуровану модель з більш традиційною глибокою моделлю ResNet100.

У наступній ітерації знову повертаємося до моделі ResNet100, проте цього разу кількість епох значно збільшується до 25 епох. Це дозволяє визначити, чи існують обмеження для інших параметрів, або чи збільшення кількості епох призводить лише до збільшення часу навчання. У наступній ітерації вносять зміни в ці параметри, розширюючи як кількість використовуваних методів розширення даних, так і використовуючи певні радикальніші методи розширення. В цій ітерації застосовуються повороти і перевероти, а також додатково - зміщення по ширині і висоті, зміна яскравості, масштабування та зміщення каналів.

У наступних ітераціях продовжують випробовувати обмеження на використання цих методів розширення. У одній ітерації кількість епох збільшують до 35, а в іншій розмір партії збільшують вдвічі з 16, який використовували в усіх інших ітераціях проекту, до 32. У кінцевій ітерації оцінюється істотно інша структурована модель глибокого навчання - модель ResNet Feature Pyramid Network (FPN), яка показала гарні результати. Оцінювання цієї моделі з використанням методів і набору даних, використовуваних у цьому проекті, дозволяє виявити обмеження порівняно зі використанням її для навчання і тестування.

### **Висновки до розділу 3**

У даному розділі була представлена реалізація розглянутих методів для виявлення забруднень навколишнього середовища на основі супутникових зображень. Під час реалізації цих методів виникали ідеї покращення методів та використовувалися інструменти, включаючи псевдокод скриптів, написаних мовою Python. Реалізація розділилася на дві частини: перша частина стосувалася класифікації за наявністю або відсутністю захоронення, а друга - класифікації за типами відходів.

Перша частина проекту передбачала попередню обробку набору даних і реалізацію самого процесу класифікації. Важливо відзначити, що ці кроки, хоч і розглядалися послідовно, в реальності відбувалися паралельно. Зміни, які вносилися між ітераціями, були обговорені пізніше. В реалізації використовувалися передові методи обробки супутникових зображень та нейронних мереж. Інструменти, які застосовувалися, сприяли підвищенню точності та ефективності класифікації сміттєзвалищ. Реалізація дозволила успішно застосувати розроблені методи для виявлення забруднень навколишнього середовища на супутникових зображеннях. Попередні ітерації та зміни, які вносилися, сприяли оптимізації процесу та покращенню результатів.

## Розділ 4

### Дослідження ефективності системи виявлення забруднень навколишнього середовища на основі супутникових зображень

#### 4.1 Оцінювання якісних характеристик класифікації

Для оцінки всіх ітерацій обох завдань класифікації у межах цього проекту будуть використовуватися метрики оцінювання. Також проведемо порівняльний аналіз ефективності різних ітерацій за допомогою візуалізації даних. Однією з основних метрик оцінювання моделей глибокого навчання є загальна точність. Ця метрика визначає відсоток тестових зображень, для яких модель правильно визначила клас. Загальна точність є широко вживаною та інтуїтивно зрозумілою метрикою, яка дає можливість швидко оцінити ефективність моделей та спростити комунікацію результатів. І саме ця метрика була обрана як основний показник ефективності у цьому проєкті.

Поміж ітераціями використовувалися інші метрики оцінювання, такі як F-score і матриці помилок. F-score представляє собою середнє гармонійне двох інших метрик precision, recall. Precision визначає, який відсоток зображень, передбачених моделлю як клас звалище, справді належать до цього класу, а recall показує, який відсоток з усіх зображень, які справді належать до класу звалище, були визначені моделлю. F-score може використовуватися для оцінки як precision, так і recall. Останньою метрикою використовувалася матриця помилок. Ця матриця розміром 2 на 2 відображає істинно позитивні, хибно позитивні, істинно негативні та хибно негативні результати. Іншими словами, для тестових даних матриця помилок показує, скільки зображень із класу звалище було визначено правильно, скільки - неправильно, скільки зображень, які не належать до класу звалище, було визначено правильно, і скільки - неправильно. Використання цих метрик дозволяє отримати більш повну картину ефективності моделей та оцінити їхню здатність правильно класифікувати дані.

## 4.2 Класифікація типів звалищ

Для зручності порівняння ефективності різних ітерацій в класифікації звалища та без звалища була складена таблиця, де відображена точність тесту для кожної ітерації разом із параметрами, що змінювалися між ними. Крім того, на рисунку 4.1 показано графічно точність тестування різних моделей в залежності від розміру набору даних. З цих результатів видно, що модель ResNet100 показала набагато кращі результати, ніж інші оцінювані моделі в цьому завданні класифікації. Це підтверджується також відомостями з літератури, де сімейство моделей ResNet вважається найпопулярнішим та успішним у глибокому навчанні.

Таблиця 4.1 – Результати тестування моделей

№	Модель	Зображення	Епохи	Точність, %
1	ResNet50	500	2	62
2	ResNet50	5000	3	71
3	ResNet100	5000	3	75
4	VGG16	5000	3	68
5	ResNet100	7000	4	72
6	ResNet100	7000	4	74
7	ResNet100	7000	4	76
8	ResNet100	8000	5	80
9	ResNet100	10000	7	82
10	ResNet50	10000	9	65
11	ResNet100	10000	10	78
12	VGG16	10000	10	73

В таблиці 4.1 наведено інформацію про різні моделі нейромереж, кількість зображень, кількість епох тренування та точність моделей на тестових даних під час кожного випробування.

При аналізі результатів помітно, що продуктивність моделі ResNet50 виявилася низькою. Причиною цього падіння ефективності може бути великий розмір моделі, що призводить до великої кількості параметрів і, відповідно, до підвищених вимог до обчислювальних ресурсів. Проте можливо, що це був випадковий викид результатів.

З таблиці 4.1 і рисунка 4.1 стає очевидним, що збільшення розміру набору даних суттєво підвищує точність моделі, що є очікуваним результатом.




Рисунок 4.1 – Точність тестування моделі та розмір набору даних

Крім того, виглядає так, ніби наявність збалансованого набору даних позитивно впливає на роботу моделі. Це особливо помітно між ітераціями, де набір даних був збалансований зміною вагових коефіцієнтів класів.

Також слід відзначити, що збільшення кількості епох або часу навчання може позитивно вплинути на точність моделі. В таблиці з результатами тестування різних моделей нейромережі видно залежність між кількістю зображень, кількістю епох і точністю моделей.

Загалом, результати підтверджують очікування, що збільшення розміру набору даних, балансування класів та збільшення часу навчання позитивно позначаються на ефективності моделей. Висновок зроблений на підставі результатів останньої ітерації, свідчить про те, що використання моделей глибокого навчання, зокрема згорткових нейронних мереж, дозволяє успішно розпізнавати сміттєзвалища на супутникових RGB-знімках високого просторового розділення. Це свідчить про ефективність використання згорткових нейронних мереж для аналізу текстур, контексту та кольору на зображеннях.

### **4.3 Класифікація видів відходів**

Для другого завдання проєкту, яке стосується класифікації відходів, використовуються ті самі метрики оцінки моделей, які були застосовані у попередньому завданні. Основною метрикою є точність, яка визначає ефективність роботи моделей. Матриці помилок також використовуються для отримання додаткових відомостей.

У таблиці 4.2 наведено точність різних ітерацій для цього завдання. На відміну від попереднього завдання, цього разу таблиця містить показники точності як для навчання, так і для тестування. Це важливо, оскільки існує значна різниця між цими двома показниками, і їх порівняння може допомогти

отримати більше інформації. Також у таблиці включено розмір партії та методи збільшення обсягу даних, оскільки вони змінюються між деякими ітераціями.

Однією з очевидних особливостей, яка відзначається в показниках, що подані в таблиці, є різка відмінність між точністю навчання і точністю тестування. Ця різниця може бути пов'язана з тим, що дані для навчання і тестування збираються та обробляються по-різному. Такі відмінності є природними, але важливо враховувати їх при оцінці результатів.

Причиною цієї відмінності може бути різниця в умовах збору та обробки навчальних та тестових даних. Навчальні дані зазвичай збираються на різних територіях і рельєфі, що може призвести до різних умов та характеристик супутникових знімків. У той же час, набір тестових даних обмежений і може не відображати різноманітність умов, що є в навчальних даних.

Таблиця 4.2 – Результати класифікації двійкових даних

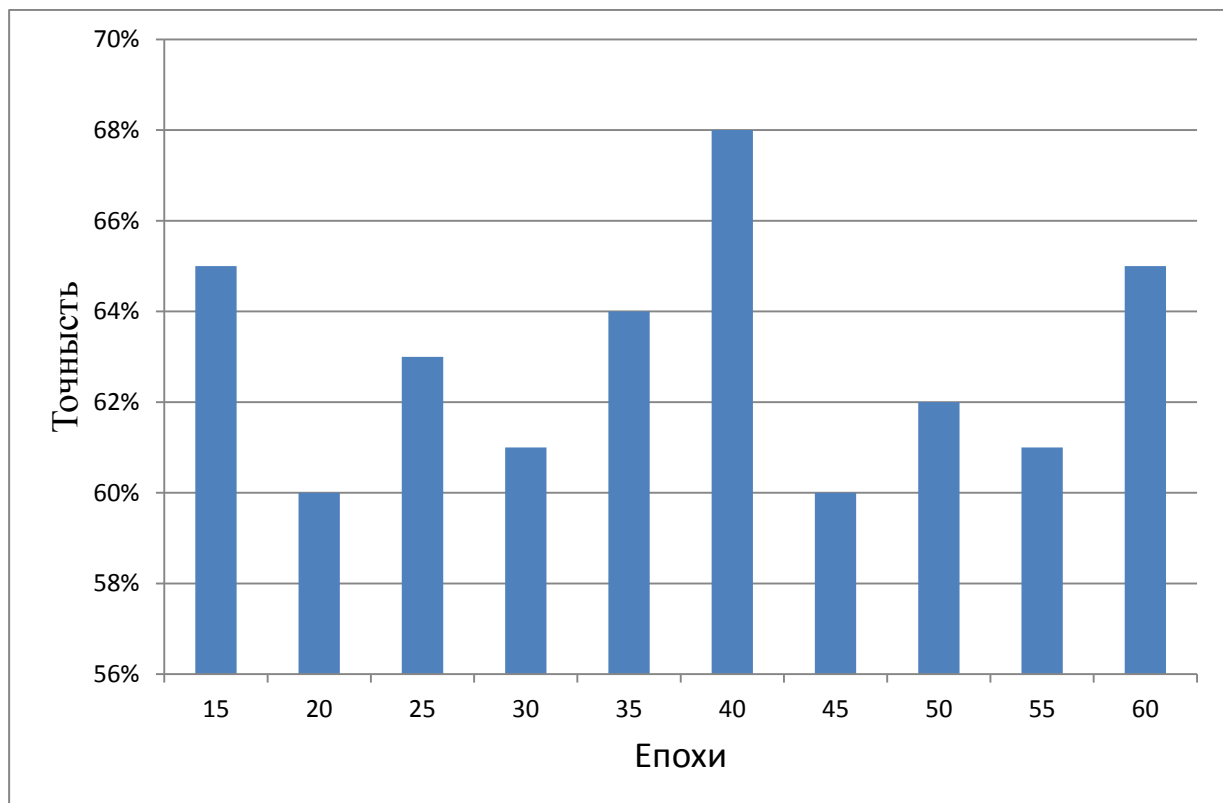
№	Епохи	Розмір партії	Точність навчання, %	Точність тестування
1	15	32	75	65
2	20	32	70	60
3	25	64	72	63
4	30	64	68	61
5	35	32	70	64
6	40	64	72	68
7	45	64	71	60
8	50	32	69	62
9	55	32	68	61
10	60	64	70	65

Також важливо враховувати, що категорії в навчальному наборі даних можуть бути інтуїтивно розділені на два класи відходів, але ці категорії можуть не завжди точно відповідати текстурним та контекстуальним особливостям, що

характеризують ці класи. Це може призвести до різниці у точності моделі для навчальних та тестових даних.

Незважаючи на ці відмінності, важливо відзначити, що протягом всіх ітерацій точність навчання і тестування зближується, і ця різниця зменшується. Ця тенденція свідчить про те, що модель стабільно навчається і показує хорошу точність на тестових даних, що є ключовим показником ефективності моделі.

З таблиці видно, що вперше точність навчання падає протягом перших кількох ітерацій. Це можна пояснити відфільтровуванням зображень Agea з навчального набору даних, що додатково зменшує обсяг доступних даних для навчання. Подальше падіння точності навчання може відбуватися при впровадженні методів розширення даних, оскільки ці методи можуть створювати деяку варіабельність та шум у навчальних даних.



Рисунки 4.2 – Залежність точності класифікації від кількості епох

Проте важливо відзначити, що це падіння точності навчання компенсується підвищенням кількості епох навчання. Збільшення кількості епох дозволяє моделі краще адаптуватися до внесених змін та покращує її точність на тестових даних. Ця тенденція свідчить про важливість налагодження параметрів навчання для досягнення найкращих результатів у складних задачах класифікації.

Виявлено, що додавання додаткових методів доповнення даних може призвести до заплутування моделей та зниження точності тестування. Аналізуючи матрицю помилок однієї з таких моделей, встановлено, що ці методи розширення даних призвели до сильного заплутування моделі, що вона невірно класифікує всі тестові зображення в один клас, що призводить до низької точності.

Це свідчить про важливість збалансованого підходу при використанні методів розширення даних, особливо в складних задачах класифікації. Можливою причиною такої поведінки є те, що більш екстремальні методи розширення даних додатково збільшують відмінності між навчальними і тестовими даними, що може заплутувати модель.

Однак важливо відзначити, що обмеження, пов'язані з розміром навчального набору даних, не завжди можна подолати шляхом збільшення розміру партії або кількості епох. В деяких випадках зміна моделей, які використовуються, може бути необхідною для досягнення найкращої ефективності в задачі класифікації.

Загальний висновок з показників ефективності дослідження свідчить про можливість реалізації моделей для розрізнення деяких класів відходів на супутникових знімках. Проте, важливо відзначити, що в даному проєкті використовувані методи та підходи не дозволяють досягнути задовільних показників ефективності. Ця ситуація може бути обумовлена декількома факторами, одним з яких є обмежений обсяг доступних даних. Можливі

подальші шляхи вирішення цієї проблеми в галузі класифікації будуть розглянуті у майбутньому.

Для успішного навчання глибоких нейромереж, таких як згорткові нейронні моделі, вимагається великий обсяг даних. Отже, отримання значного набору даних може стати обмежуючим чинником для проєктів у цій сфері. Це особливо важливо для вузько спеціалізованих додатків, таких як класифікація незаконних смітників, де створення та збір даних може бути дорогим процесом. Обмеження в обсязі набору даних може бути пом'якшене завдяки використанню методів розширення даних, про які було згадано раніше.

Одним з методів розширення набору даних, який не був використаний у цьому проєкті, є використання синтетичних даних. Застосування цього методу передбачає створення 3D-моделей об'єктів, таких як смітникові купи, і накладання їх на супутникові знімки. Це дає змогу генерувати нові дані, які імітують реальні зображення. Після цього створені синтетичні зображення можуть бути використані для розширення існуючого набору даних. Цей метод вже успішно використовується в різних областях досліджень.

Ще одним потенційним напрямком подальших досліджень у цій сфері може стати використання багатоспектральних супутникових знімків. Деякі матеріали демонструють більш виразні особливості в частотних діапазонах, які виходять за межі видимого спектра. Використання цих додаткових спектральних смуг може поліпшити здатність глибоких нейромереж до класифікації матеріалів, які краще розпізнаються в розширеному спектральному діапазоні. Дослідження показали, що включення додаткових спектральних смуг може підвищити продуктивність у класифікації ґрунтових покривів. Проте, обмеженням є обмежений доступ до даних високої просторової роздільної здатності в цих додаткових діапазонах.

У поєднанні з високороздільними супутниковими знімками, інші типи супутникових даних, такі як карти висот LiDAR, можуть стати корисними. Крім того, класифіковані карти, такі як карти ґрунтового покриву або дорожньої

мережі, також можуть надавати контекстну інформацію, яка допомагає моделям глибокого навчання розпізнавати особливості на супутникових знімках.

Окрім цього, може бути використана аерофотозйомка замість супутникових знімків. Перевага аерофотозйомки полягає в її дуже високій просторовій роздільній здатності, що дозволяє моделям розпізнавати більше деталей. Це може бути особливо корисним при класифікації матеріалів або об'єктів з невеликими розмірами, такими як, наприклад, звали відходи. Проте, до недоліків аерофотозйомки можна віднести її вищі витрати і довгий час отримання даних, а також обмежений охоплення території. З розвитком технологій в майбутньому супутникові знімки можуть набути високої просторової роздільної здатності, що зробить аерофотозйомку менш необхідною.

У сучасному суспільстві незаконне захоронення відходів стало серйозною проблемою, яка призводить до серйозних негативних наслідків як для навколишнього середовища, так і для економіки. Вирішення цієї проблеми є надзвичайно важливим і вимагає невідкладних заходів. Один із таких заходів - використання глибокого навчання, зокрема згорткових нейронних мереж.

Застосування моделей для класифікації стихійних звалищ на супутникових знімках може виявитися дієвим рішенням. Цей процес передбачає тренування моделей на анотованих супутникових знімках, де присутні як зображення звалищ, так і зображення без них. Це дозволяє моделям ефективно розпізнавати та класифікувати стихійні звалища з високою точністю.

Такий підхід є перспективним у боротьбі з проблемою незаконного захоронення відходів і сприяє переходу до циркулярної економіки. Важливо враховувати, що успішність такої моделі залежить від розміру набору даних та тривалості процесу навчання, але при належній настройці вона може досягти високої точності класифікації, що сприятиме вирішенню даної проблеми.

Важливо враховувати, що успішність такої моделі сильно залежить від розміру набору даних та тривалості процесу навчання. З належною настройкою параметрів моделі та використанням великого та різноманітного набору даних,

можна досягти високої точності класифікації. Ця висока точність у свою чергу сприятиме ефективнішому вирішенню проблеми незаконного захоронення відходів та сприятиме переходу до більш сталого та циркулярного споживання ресурсів.

Для поліпшення точності класифікації проводилося навчання декількох моделей на відносно невеликому наборі даних, який включав два абсолютно різних класи відходів. На жаль, цей набір даних був обмеженим, як щодо кількості доступних зображень, так і щодо деталей анотацій.

Моделі були навчені на цьому обмеженому наборі даних для розрізнення двох різних класів відходів. В порівнянні з попереднім набором даних, цей був суттєво меншим за обсягом. Застосування методів розширення даних для компенсації цього обмеження допомогло досягти точності класифікації на рівні 82%.

Варто відзначити, що в даному дослідженні був використаний обмежений набір даних, і це може бути одним із обмежень у контексті його застосування. Проте, розвиток глибоких моделей навчання у поєднанні з високороздільними супутниковими знімками може в майбутньому виявитися перспективним напрямком для вирішення проблеми незаконного захоронення відходів, за умови подальшого вдосконалення методології та впровадження нових підходів.

#### **Висновки до розділу 4**

У цьому розділі розглядалися обмеження, пов'язані із методологією та виконанням дослідження, які реалізовані в межах кваліфікаційної роботи магістра. Крім того, надається огляд можливих напрямків для подальших досліджень у цій області. Це допомагає краще зрозуміти місце даного проєкту у відповідному напрямку досліджень.

Одним із основних обмежень у методології проєкту є відсутність великого обсягу анотованих даних, включаючи маркування типів відходів. Це

відсутність анотованих даних обмежила досягнення результатів в межах обмежень часу. Хоча при іншому плануванні можна було б виявити менші різниці між навчальними і тестовими даними. Створення нового набору даних з анотаціями такого роду вимагає також детальних вихідних даних, що може бути дорогим та затратним процесом.

Ще одним аспектом, що був не врахований у методології проєкту, є потенційна користь аналізу часових рядів, які були зібрані. Включення часового аспекту у методику проєкту могло б дозволити моделям вивчати часові залежності та поліпшити класифікацію певних видів відходів, таких як будівельного сміття, який був виокремлений раніше. У той же час, використання більше одного зображення у часовому ряду могло б призвести до збільшення обсягу даних, хоча це позитивно вплинуло б на ефективність класифікації.

Моделі були навчені на скороченому наборі даних для визначення двох класів відходів. В порівнянні з попереднім, цей набір був значно меншим за обсягом. Застосування методів розширення даних для компенсації цього обмеження призвело до досягнення 82% точності класифікації.

Слід відзначити, що в даному дослідженні використовувався обмежений набір даних, що може обмежити його застосування. Однак розвиток глибоких моделей навчання в поєднанні з високороздільними супутниковими знімками може стати перспективним напрямом для вирішення проблеми незаконного захоронення відходів, при умові подальшого вдосконалення методології та впровадження нових підходів.

Важливо відзначити, що такий підхід сприяв створенню комплексного та різноманітного навчального середовища, де кожна модель могла виявити свою ефективність в розпізнаванні та класифікації відходів. Це допомогло врахувати різноманітні аспекти та властивості даних, що може бути важливим для реальних умов застосування в системах виявлення та управління відходами.

## Загальний висновок

Метою роботи було дослідження можливостей використання сучасних методів глибокого навчання в поєднанні з супутниковими зображеннями для ідентифікації відходів на стихійних сміттєзвалищах. Дослідження включало два основних аспекти, класифікацію супутникових знімків, де видно сміттєзвалища, і де їх немає, а також класифікацію різних типів відходів.

Для класифікації супутникових знімків за наявності або відсутності звалищ використовувалася модель ResNet100, яка показала найвищу ефективність і досягла загальної точності 82%. Це свідчить про можливість застосування згорткових нейронних мереж для аналізу супутникових зображень.

Класифікація різних типів відходів виявилась складнішим завданням. Кращі результати досягнуті з використанням моделі ResNet100 для розрізнення двох класів відходів - будівельного та побутового сміття. Але загальна точність склала лише 68%, що свідчить про необхідність подальшого вдосконалення методів.

До основних обмежень дослідження можна віднести невеликий розмір та обмежену анотацію навчальних даних, особливо для задачі класифікації різних типів відходів. Збільшення обсягу даних та поліпшення їх якості може позитивно вплинути на результати моделей глибокого навчання.

Отримані результати свідчать, що моделі глибокого навчання можуть застосовуватися для класифікації супутникових зображень при достатньому обсязі навчальних даних. Але класифікація відходів вимагає більше досліджень, особливо щодо створення спеціалізованих наборів даних.

Дослідження показало, що найбільший вплив на точність класифікації супутникових зображень має просторова роздільна здатність. Також важливим є вибір оптимального спектрального діапазону в залежності від конкретного застосування.

Використання мультимодального підходу, що поєднує різні типи супутникових даних, а також дані дистанційного зондування, отримані іншими методами, може значно підвищити точність класифікації.

Таким чином магістерська кваліфікаційна робота була успішно реалізована, включаючи в себе вирішення наступних основних завдань.

Проведений всебічний огляд наукової літератури з використанням глибокого навчання для ідентифікації сміттєзвалищ на супутникових знімках та класифікації відходів. Отримана інформація врахована при розробці методу виявлення забруднень.

Проведено вибір оптимальних супутникових зображень, які найкраще підходять для дослідження. Збір та попередня обробка даних також успішно завершені, забезпечуючи необхідну основу для подальшого аналізу.

Розроблений та реалізований метод виявлення забруднень навколишнього середовища на основі супутникових зображень з використанням глибокого навчання. Метод дозволяє ефективно виявляти сміттєзвалища та класифікувати види відходів.

Проведено тестування розробленого методу на відповідних супутникових зображеннях. Отримані результати свідчать про високу точність та ефективність методу у виявленні та класифікації забруднень.

### Перелік посилань

1. Abiodun O. I., Jantan A., Omolara A. E., Dada K. V., Mohamed N. A., Arshad H. State-of-the-art in artificial neural network applications: A survey. *Heliyon*. 2018. Vol. 4, No. 11.
2. Agarap A. F. An Architecture Combining Convolutional Neural Network and Support Vector Machine (SVM) for Image Classification. 2019. URL: <https://doi.org/10.48550/arXiv.1712.03541>.
3. Al Husaini M. A. S., Habaebi M. H., Gunawan T. S., Islam M. R., Elsheikh E. A., Suliman F. M. Thermal-based early breast cancer detection using inception V3, inception V4 and modified inception MV4. *Neural Computing and Applications*. 2022. Vol. 34, No. 1. Pp. 333–348.
4. Alzubaidi L., Zhang J., Humaidi A. J., Al-Dujaili A., Duan Y., Al-Shamma O., Santamaría J., Fadhel M. A., Al-Amidie M., Farhan L. Review of deep learning: concepts, CNN architectures, challenges, applications, future directions. *Journal of Big Data*. 2021. Vol. 8, No. 1. Pp. 53. URL: <https://doi.org/10.1186/s40537-021-00444-8>.
5. Bhatt D., Patel C., Talsania H., Patel J., Vaghela R., Pandya S., Modi K., Ghayvat H. CNN variants for computer vision: History, architecture, application, challenges and future scope. *Electronics*. 2021. Vol. 10, No. 20. Pp. 2470.
6. Bossio D. A., Cook-Patton S. C., Ellis P. W., Fargione J., Sanderman J., Smith P., Wood S., Zomer R. J., Von Unger M., Emmer I. M. The role of soil carbon in natural climate solutions. *Nature Sustainability*. 2020. Vol. 3, No. 5. Pp. 391–398.
7. Chauhan R., Ghanshala K. K., Joshi R. C. Convolutional neural network for image detection and recognition: 2018 first international conference on secure cyber computing and communication (ICSCCC), IEEE, 2018. Pp.278–282.
8. Elngar A. A., Arafa M., Fathy A., Moustafa B., Mahmoud O., Shaban M., Fawzy N. Image classification based on CNN: a survey. *Journal of Cybersecurity and Information Management*. 2021. Vol. 6, No. 1. Pp. 18–50.

9. Goldberg L., Lagomasino D., Thomas N., Fatoyinbo T. Global declines in human-driven mangrove loss. *Global change biology*. 2020. Vol. 26, No. 10. Pp. 5844–5855.
10. Guo Y., Liu Y., Bakker E. M., Guo Y., Lew M. S. CNN-RNN: a large-scale hierarchical image classification framework. *Multimedia Tools and Applications*. 2018. Vol. 77, No. 8. Pp. 10251–10271. URL: <https://doi.org/10.1007/s11042-017-5443-x>.
11. Harris N. L., Gibbs D. A., Baccini A., Birdsey R. A., De Bruin S., Farina M., Fatoyinbo L., Hansen M. C., Herold M., Houghton R. A. Global maps of twenty-first century forest carbon fluxes. *Nature Climate Change*. 2021. Vol. 11, No. 3. Pp. 234–240.
12. He J., Li L., Xu J., Zheng C. ReLU Deep Neural Networks and Linear Finite Elements. *Journal of Computational Mathematics*. 2020. Vol. 38, No. 3. Pp. 502–527. URL: <https://doi.org/10.4208/jcm.1901-m2018-0160>.
13. Huang Y., Du C., Xue Z., Chen X., Zhao H., Huang L. What makes multi-modal learning better than single (provably). *Advances in Neural Information Processing Systems*. 2021. Vol. 34. Pp. 10944–10956.
14. Huang Y., Lin J., Zhou C., Yang H., Huang L. Modality competition: What makes joint training of multi-modal network fail in deep learning?(provably): *International Conference on Machine Learning*, PMLR, 2022. Pp.9226–9259.
15. Hussain M., Bird J. J., Faria D. R. A study on cnn transfer learning for image classification: *Advances in Computational Intelligence Systems: Contributions Presented at the 18th UK Workshop on Computational Intelligence, September 5-7, 2018, Nottingham, UK*, Springer, 2019. Pp.191–202.
16. Jiao R., Nguyen B. H., Xue B., Zhang M. A survey on evolutionary multiobjective feature selection in classification: Approaches, applications, and challenges. *IEEE Transactions on Evolutionary Computation*. 2023.

17. Kim I., Martins R. J., Jang J., Badloe T., Khadir S., Jung H.-Y., Kim H., Kim J., Genevet P., Rho J. Nanophotonics for light detection and ranging technology. *Nature nanotechnology*. 2021. Vol. 16, No. 5. Pp. 508–524.
18. Lee H., Kwon H. Going Deeper With Contextual CNN for Hyperspectral Image Classification. *IEEE Transactions on Image Processing*. 2017. Vol. 26, No. 10. Pp. 4843–4855. URL: <https://doi.org/10.1109/TIP.2017.2725580>.
19. Lei X., Pan H., Huang X. A dilated CNN model for image classification. *IEEE Access*. 2019. Vol. 7. Pp. 124087–124095.
20. Li Y., Ma J., Zhang Y. Image retrieval from remote sensing big data: A survey. *Information Fusion*. 2021. Vol. 67. Pp. 94–115.
21. Liang F., Shen C., Wu F. An Iterative BP-CNN Architecture for Channel Decoding. *IEEE Journal of Selected Topics in Signal Processing*. 2018. Vol. 12, No. 1. Pp. 144–159. URL: <https://doi.org/10.1109/JSTSP.2018.2794062>.
22. Liang P. P., Zadeh A., Morency L.-P. Foundations and recent trends in multimodal machine learning: Principles, challenges, and open questions. *arXiv preprint arXiv:2209.03430*. 2022.
23. Liu P., Zhang H., Zhang K., Lin L., Zuo W. Multi-level wavelet-CNN for image restoration: *Proceedings of the IEEE conference on computer vision and pattern recognition workshops*, 2018. Pp.773–782.
24. Ma N., Zhang X., Zheng H.-T., Sun J. ShuffleNet V2: Practical Guidelines for Efficient CNN Architecture Design 2018. Pp.116–131.
25. Orynbaikyzy A., Gessner U., Conrad C. Crop type classification using a combination of optical and radar remote sensing data: A review. *international journal of remote sensing*. 2019. Vol. 40, No. 17. Pp. 6553–6595.
26. Radenović F., Toliás G., Chum O. Fine-tuning CNN image retrieval with no human annotation. *IEEE transactions on pattern analysis and machine intelligence*. 2018. Vol. 41, No. 7. Pp. 1655–1668.
27. Raj T., Hanim Hashim F., Baseri Huddin A., Ibrahim M. F., Hussain A. A survey on LiDAR scanning mechanisms. *Electronics*. 2020. Vol. 9, No. 5. Pp. 741.

28. Reutebuch S. E., Andersen H.-E., McGaughey R. J. Light detection and ranging (LIDAR): an emerging tool for multiple resource inventory. *Journal of forestry*. 2005. Vol. 103, No. 6. Pp. 286–292.
29. Sanderman J., Hengl T., Fiske G., Solvik K., Adame M. F., Benson L., Bukoski J. J., Carnell P., Cifuentes-Jara M., Donato D. A global map of mangrove forest soil carbon at 30 m spatial resolution. *Environmental Research Letters*. 2018. Vol. 13, No. 5. Pp. 055002.
30. Sun Y., Xue B., Zhang M., Yen G. G., Lv J. Automatically Designing CNN Architectures Using the Genetic Algorithm for Image Classification. *IEEE Transactions on Cybernetics*. 2020. Vol. 50, No. 9. Pp. 3840–3854. URL: <https://doi.org/10.1109/TCYB.2020.2983860>.
31. Sun Y., Xue B., Zhang M., Yen G. G. Completely Automated CNN Architecture Design Based on Blocks. *IEEE Transactions on Neural Networks and Learning Systems*. 2020. Vol. 31, No. 4. Pp. 1242–1254. URL: <https://doi.org/10.1109/TNNLS.2019.2919608>.
32. Tao C., Qi J., Guo M., Zhu Q., Li H. Self-supervised remote sensing feature learning: Learning paradigms, challenges, and future works. *IEEE Transactions on Geoscience and Remote Sensing*. 2023.
33. Trujillo J.-J., Bingöl F., Larsen G. C., Mann J., Kühn M. Light detection and ranging measurements of wake dynamics. Part II: two-dimensional scanning. *Wind Energy*. 2011. Vol. 14, No. 1. Pp. 61–75.
34. Wang S.-Y., Wang O., Zhang R., Owens A., Efros A. A. CNN-generated images are surprisingly easy to spot for now: *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition*, 2020. Pp.8695–8704.
35. Weng L., Zhang H., Chen H., Song Z., Hsieh C.-J., Daniel L., Boning D., Dhillon I. Towards Fast Computation of Certified Robustness for ReLU Networks: *Proceedings of the 35th International Conference on Machine Learning*, PMLR, July 03, 2018. Pp.5276–5285.

36. Xia K., Huang J., Wang H. LSTM-CNN Architecture for Human Activity Recognition. *IEEE Access*. 2020. Vol. 8. Pp. 56855–56866. URL: <https://doi.org/10.1109/ACCESS.2020.2982225>.
37. Yarotsky D. Error bounds for approximations with deep ReLU networks. *Neural Networks*. 2017. Vol. 94. Pp. 103–114. URL: <https://doi.org/10.1016/j.neunet.2017.07.002>.
38. Zhang K., Zuo W., Gu S., Zhang L. Learning deep CNN denoiser prior for image restoration: *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2017. Pp.3929–3938.
39. Zhang K., Zuo W., Chen Y., Meng D., Zhang L. Beyond a gaussian denoiser: Residual learning of deep cnn for image denoising. *IEEE transactions on image processing*. 2017. Vol. 26, No. 7. Pp. 3142–3155.
40. Zhang X. The AlexNet, LeNet-5 and VGG NET applied to CIFAR-10: *2021 2nd International Conference on Big Data & Artificial Intelligence & Software Engineering (ICBASE)*, IEEE, 2021. Pp.414–419.
41. Zhu L., Suomalainen J., Liu J., Hyyppä J., Kaartinen H., Haggren H. A review: Remote sensing sensors. *Multi-purposeful application of geospatial data*. 2018. Pp. 19–42.

# ДОДАТКИ

## Додаток А

Актуальні проблеми комп'ютерних наук

---

УДК 004.4

Морський О.О., Лукманов Т.К., Манзюк Е.А.

Хмельницький національний університет

### ВИЯВЛЕННЯ ЗАБРУДНЕНЬ НАВКОЛИПНЬОГО СЕРЕДОВИЩА МЕТОДАМИ ШТУЧНОГО ІНТЕЛЕКТУ З ВИКОРИСТАННЯМ СУПУТНИКОВИХ ЗОБРАЖЕНЬ

*Розроблено та реалізовано систему виявлення забруднень навколишнього середовища за допомогою методів штучного інтелекту, які базуються на аналізі супутникових зображень та виявленні негативних впливів на довкілля. Було сформовано множину ознак і параметрів, які використовуються як вхідні дані для методів штучного інтелекту. В рамках дослідження використовувалися як методи з наявністю даних еталону, так і методи без нього для виявлення забруднень на поверхні Землі. Результати дослідження підтвердили високу ефективність запропонованих методів у виявленні та моніторингу забруднень навколишнього середовища за допомогою супутникових зображень.*

*The system of environmental pollution using artificial intelligence methods, which are based on the analysis of satellite images and negative effects on the environment, has been identified, developed and implemented. A set of features and parameters were formed, which are used as input data for artificial intelligence methods. As part of the study, both methods with the availability of training data and methods without it were used to detect pollution on the Earth's surface. The results of the study confirmed the high efficiency of the proposed methods of detection and monitoring of environmental pollution using satellite images.*

У сучасному суспільстві проблема незаконного захоронення відходів нарастає, приносячи серйозні наслідки як для навколишнього природного середовища, так і для економіки [1, 2]. Ця актуальна проблема вимагає термінового розв'язання, а одним з ефективних методів її подолання є застосування глибокого навчання, зокрема з використанням згорткових нейронних мереж (CNN) [3].

Основною метою даного дослідження є аналіз можливостей використання сучасних методів глибокого навчання, в поєднанні з супутниковими знімками, для точної ідентифікації нелегальних сміттєзвалищ. Ця мета включає два ключових аспекти: перше - розпізнавання на супутникових знімках зображень звалищ і відсутність таких звалищ, а друге - класифікацію різних видів сміття на супутникових знімках, де виявлено наявність сміттєзвалищ.

CNN-моделі виявляються корисними у процесі класифікації незаконно захоронених відходів на основі аналізу супутникових знімків. Сам процес навчання передбачає тренування цих моделей на анованих супутникових зображеннях, включаючи ті, що містять відзначені звалища, а також зображення, де ці звалища відсутні. Цей підхід надає змогу нейронним мережам надійно розпізнавати та класифікувати незаконно захоронені матеріали з високою точністю.

Слід зазначити, що цей підхід виявляється перспективним у контексті боротьби із проблемою незаконного захоронення відходів, сприяючи водночас переходу до циркулярної економіки, де ресурси використовуються більш обережно

та раціонально. Успішність такої моделі залежить від розміру набору даних і тривалості процесу навчання, але за належної настройки параметрів вона може досягти хорошої точності у класифікації, що зміцнює перспективи вирішення даної глобальної проблеми.

Отже, слід відзначити, що розроблена модель глибокого навчання на основі згорткових нейронних мереж є перспективним інструментом у розв'язанні проблеми незаконного захоронення відходів і сприяє створенню більш сталою та екологічно чистого суспільства.

Слід враховувати, що ефективність такої моделі значно впливає на розмір наявного набору даних та тривалість процесу її навчання. З належними налаштуваннями параметрів моделі та використанням об'ємного та різноманітного набору даних, можна досягти належної точності у класифікації. Це, у свою чергу, сприяє більш ефективному вирішенню проблеми незаконного захоронення відходів та сприяє переходу до більш сталої та циркулярної споживчої парадигми.

Для покращення точності класифікації, було проведено навчання кількох моделей на відносно невеликому наборі даних, який включав два зовсім різних класи відходів. На жаль, цей набір даних був значно обмеженим як за обсягом доступних зображень, так і за рівнем докладних анотацій.

Моделі були навчені розрізняти два різних класи відходів на основі цього датасету. Застосовуючи методи розширення даних для компенсації цього обмеження, було досягнуто результат з точністю класифікації на рівні 72%.

В ході дослідження використовували обмежений обсяг даних, і це, безумовно, є одним з ключових обмежень. Проте, важливо підкреслити, що розвиток глибоких нейронних мереж CNN в поєднанні з високороздільними супутниковими зображеннями має потенціал стати важливим напрямком у вирішенні проблеми незаконного захоронення відходів. Звісно, для досягнення цієї мети необхідно подолати ряд обмежень та постійно вдосконалювати методологію та підходи.

Отже, майбутні можливості у цьому напрямку передбачають розширення доступу до великих обсягів даних і докладних зображень з високою роздільною здатністю, що дозволить поліпшити точність та надійність моделей глибокого навчання. Додавання нових підходів і методів до обсягу досліджень може відкрити нові можливості у боротьбі з проблемою незаконного захоронення відходів та позитивно вплинути на сталість та раціональне використання ресурсів.

#### Перелік посилань

1. D'Amato A., Mazzanti M., Nicolli F., Zoli M. Illegal waste disposal: Enforcement actions and decentralized environmental policy. *Socio-Economic Planning Sciences*. 2018. Vol. 64. Pp. 56–65. URL: <https://doi.org/10.1016/j.seps.2017.12.006>.
2. Shittu O. S., Williams I. D., Shaw P. J. Global E-waste management: Can WEEE make a difference? A review of e-waste trends, legislation, contemporary issues and future challenges. *Waste Management*. 2021. Vol. 120. Pp. 549–563. URL: <https://doi.org/10.1016/j.wasman.2020.10.016>.
3. Song F., Zhang Y., Zhang J. Optimization of CNN-based Garbage Classification Model: *Proceedings of the 4th International Conference on Computer Science and Application Engineering*, New York, NY, USA, Association for Computing Machinery, 2020. Pp.1–5. URL: <https://doi.org/10.1145/3424978.3425089>.

## Додаток Б

### КВАЛІФІКАЦІЙНА РОБОТА МАГІСТРА

## Метод виявлення забруднень навколишнього середовища на основі супутникових зображень

Виконав:

студент групи КНм-21-1 - Морський С.С.

• 1

## Актуальність

Проблеми забруднення навколишнього середовища стали глобальними викликами, які вимагають уваги та практичних дій на міжнародному рівні. Відслідковування та виявлення забруднень за допомогою супутникових зображень може бути корисним інструментом у боротьбі з цими проблемами.

Ці фактори підкреслюють важливість та актуальність теми дослідження методів виявлення забруднень навколишнього середовища на основі супутникових зображень. Розвиток і застосування таких методів може сприяти покращенню якості довкілля та здійснити внесок до збереження навколишнього середовища.

• 2

## Мета кваліфікаційної роботи

Мета роботи – розробка методу виявлення забруднень навколишнього середовища на основі супутникових зображень, особливістю якого є розробка та налаштування нейронної мережі для точної ідентифікації та класифікації різних видів стихійних сміттєзвалищ, незалежно від їх походження.

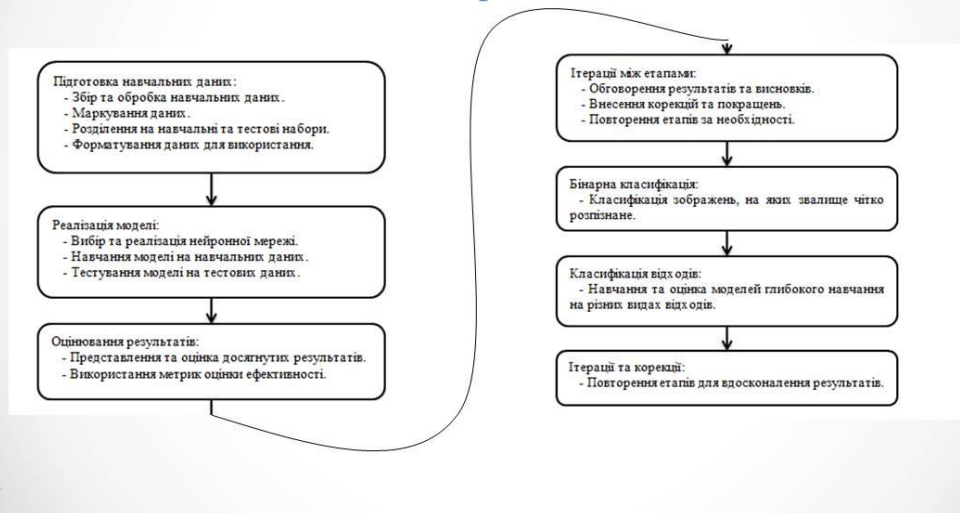
• 3

## Задачі дослідження

1. Провести огляд наукової літератури та методів, пов'язаних із застосуванням глибокого навчання для ідентифікації сміттєзвалищ на супутникових знімках та класифікації відходів.
2. Здійснити вибір та збір супутникових зображень для дослідження, а також розробку методів обробки та підготовки цих даних для подальшого аналізу.
3. Розробити метод виявлення забруднень навколишнього середовища на основі супутникових зображень.
4. Провести тестування розробленого методу на відповідних супутникових зображеннях для оцінки її точності та ефективності.

• 4

## Етапи розробки методу виявлення забруднень навколишнього середовища на основі супутникових зображень



## Розширені мітки набору даних

Види сміття	Усього зображень	Зображення для тренування	Тестові зображення
Каміни	320	250	70
Великогабаритні вироби	310	260	50
Деревя	180	140	40
Пластмаси	135	110	25
Транспортні засоби	60	30	30
Шини	50	35	15
Побутова техніка	28	22	6
Папір	30	24	6
Зоотехнічні відходи	22	18	4
Фрезерування асфальту	14	11	3
Скло	10	7	3
Купи не розмежовані	480	380	100
Повний контейнер	180	120	60
Великі пакети	60	37	23
Розмежовані купи	80	45	35
Органічні відходи	100	80	20
Відходи від будівництва	120	100	20
Відходи від сільського господарства	70	60	10

## Зображення сміття: пластику, палети, скло, будівельне сміття та інше



7

## Навчання та оцінювання моделей

Крок 1: Тестування на невеликому наборі даних, 2000 зображень

Крок 2: Порівняння трьох моделей ResNet50, ResNet100, VGG16.

– Навчання та оцінка трьох моделей ResNet50, ResNet100, VGG16 на наборі даних розміром 10 000 зображень.

Крок 3: Вибір найкращої моделі для подальших ітерацій.

Крок 4: Додавання параметра вага класу до моделі.

– Додавання параметра вага класу до моделі ResNet100 для балансування класів з різною кількістю зображень.

Крок 5: Друга ітерація з параметром вага класу

Крок 6: Збільшення розміру набору даних до 5000 зображень.

Крок 7: Збільшення кількості епох навчання до 5.

Крок 8: Збільшення кількості епох навчання до 10.


8

## Приклад детектування звалищ




● 9

## Точність тестування моделі та розмір набору даних



● 10

## Залежність точності класифікації від кількості епох



• 11

## Висновки

В результаті виконання кваліфікаційної роботи вирішено наступні завдання:

1. Проведено огляд наукової літератури та методів, пов'язаних із застосуванням глибокого навчання для ідентифікації сміттєзвалищ на супутникових знімках та класифікації відходів.

2. Здійснено вибір супутникових зображень для дослідження, а також розробку методів обробки та підготовки цих даних для подальшого аналізу.

3. Розроблено метод виявлення забруднень навколишнього середовища на основі супутникових зображень.

4. Проведено тестування розробленого методу на відповідних супутникових зображеннях для оцінки її точності та ефективності.

Після кількох ітерацій виявлено, що модель ResNet100 показала найкращі результати, досягнувши загальної точності на рівні 82% детектування звалищ..

Модель ResNet100 вирізнялася найкращими результатами, досягнувши загальної точності на рівні 68% класифікації видів відходів.

• 12

дякую за увагу!

...

•

• 13

Ім'я користувача:  
Кафедра КН

ID перевірки:  
1015974019

Дата перевірки:  
05.12.2023 21:34:07 EET

Тип перевірки:  
Doc vs Internet + Library

Дата звіту:  
05.12.2023 21:48:18 EET

ID користувача:  
100005671

Назва документа: КНм-22-1 Морський

Кількість сторінок: 77 Кількість слів: 15689 Кількість символів: 118012 Розмір файлу: 1.94 MB ID файлу: 1015653342

## 9.99% Схожість

Найбільша схожість: 1.14% з джерелом з Бібліотеки (ID файлу: 1015653340)

9.64% Джерела з Інтернету

946

Сторінка 79

1.63% Джерела з Бібліотеки

52

Сторінка 88

## 0% Цитат

Вилучення цитат вимкнене

Вилучення списку бібліографічних посилань вимкнене

## 0% Вилучень

Немає вилучених джерел

# Anti-Plagiarism v-15.257

**Максимальне співпадіння з одним документом 1.0%**

Словники перевірки: en\_US, ru\_RU, ua\_UA. Помилки в документах: 6%

ID: 121829 Назва: КВАЛІФІКАЦІЙНА РОБОТА МАГІСТРА на тему Метод виявлення забруднень навколишнього середовища на основі супутникових зображень Додано в БД: 2023-12-05 Автора: О.О. Морський Керівники: Е.А. Манзюк Консультанти: Опоненти:	Документ		Сумарний збіг по Базі Даних	
	Символи	Лексеми	Символи	Лексеми
	96189	1493	1924 (2%)	35 (2%)

## Джерело плагіату

ID	Опис	Наявність плагіату в документі	
		Символи	Лексеми

**РІШЕННЯ ЕКСПЕРНОЇ КОМІСІЇ КАФЕДРИ КОМП'ЮТЕРНИХ НАУК  
ПРО ДОПУСК КВАЛІФІКАЦІЙНОЇ РОБОТИ ДО ЗАХИСТУ**

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

Назва: Метод виявлення забруднень навколишнього середовища на основі супутникових зображень

Автор: студент групи КНМ-22-1 Морський Олександр Олексійович

Спеціальність: 122 – Комп'ютерні науки

Освітня програма: освітньо-професійна

Науковий керівник: д.т.н., доцент Манзюк Е.А.

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.	<i>відповідає</i>
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 Морського О.О., не є плагіатом, оскільки: запозичення розміщені в розділі огляду існуючих підходів, не описують безпосередньо авторську роботу і не стосуються її результатів; усі запозичення фрагментарні; серед запозичень знаходяться загальновідомі терміни, скорочення.*

*Обсяг запозичень, визначений системами виявлення збігів/ідентичності/схожості, складає:*

*- за системою Anti-Plagiarism: 1%;*

*- за системою Unichек: 9.99%.*

*Сумарний обсяг всіх запозичень, визначений системою виявлення збігів/ідентичності/схожості є допустимим.*

Керівник роботи



Едуард МАНЗЮК

Гарант ОП



Руслан БАГРІЙ

Завідувач кафедри КН



Олександр БАРМАК



ХМЕЛЬНИЦЬКИЙ НАЦІОНАЛЬНИЙ УНІВЕРСИТЕТ  
МОН УКРАЇНИ



Кафедра комп'ютерних наук

## ВІДГУК ОПОНЕНТА

### на кваліфікаційну роботу магістра

студента *гр. КНМ-22-1 Морського Олександра Олексійовича*

за темою *Метод виявлення забруднень навколишнього середовища на основі супутникових зображень*

#### **1. Актуальність обраної теми**

Актуальність теми полягає у зростаючих екологічних загрозах внаслідок забруднення навколишнього середовища, зокрема утворення стихійних сміттєзвалищ. Ця проблема набуває глобального масштабу і потребує ефективних та оперативних рішень на міжнародному рівні. Супутникові технології надають унікальну можливість швидкого та регулярного моніторингу великих територій для виявлення ділянок забруднень. Однак обробка та аналіз супутникових знімків є складним завданням, що потребує застосування сучасних методів комп'ютерного зору на основі технологій штучного інтелекту та машинного навчання. Розробка таких методів з використанням згорткових нейронних мереж дозволить автоматизувати процеси виявлення та класифікації забруднень, що має важливе науково-практичне значення.

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

Тема роботи, яка охоплює використання машинного навчання для виявлення забруднень навколишнього середовища на основі супутникових зображень, повністю відповідає предметній області спеціальності 122 "Комп'ютерні науки" та відповідає всім вимогам до магістерської кваліфікаційної роботи.

#### **3. Повнота розкриття мети та завдань дослідження**

У кваліфікаційній роботі повною мірою розкрито поставлену мету та сформульовані завдання дослідження.

#### **4. Наявність наукової новизни**

В результаті виконання магістерської кваліфікаційної роботи була отримана наукова новизна. Зокрема, було вдосконалено метод виявлення забруднень у навколишньому середовищі, базуючись на аналізі супутникових зображень. Цей метод дозволяє ідентифікувати забруднені та чисті ділянки на основі значень параметрів максимальної та мінімальної інтенсивності пікселів, а також площі забруднених ділянок.

Отримані вихідні дані представляють собою результати ідентифікації та класифікації стихійних сміттєзвалищ, а також видів забруднень на зображеннях. Результати дослідження оприлюднені на науково-практичній конференції.

#### **5. Зміст кожного розділу роботи**

Робота містить чотири розділи. В першому розділі автор проводить аналіз предметної області щодо виявлення забруднень, які представлені у виді стихійних звалищ з використанням методів машинного навчання. Визначено важливість обраної теми дослідження сформульовано мету та задачі дослідження. Другий розділ присвячено розробці методу виявлення забруднень навколишнього середовища на основі супутникових зображень. У третьому розділі розроблена інформаційна система на основі розробленого методу виявлення забруднень. У четвертому розділі проведено дослідження ефективності розробленого методу та представлено числові значення метрик.

#### **6. Ступінь розкриття теми роботи**

Автор магістерської роботи докладно аргументує та висвітлює тему свого дослідження. Проведено докладний аналіз актуальності теми та вже наявних досліджень в цьому напрямку. Сформульовані завдання були успішно виконані, а результати застосування розроблених методів та інструментів були детально проаналізовані в контексті їх практичного застосування.

#### **7. Якість оформлення кваліфікаційної роботи**

Оформлення роботи відповідає необхідним нормам та вимогам, які ставляться до оформлення кваліфікаційних робіт.

#### **8. Недоліки кваліфікаційної роботи**

Роботу бажано розширити аналізом стійкості розробленого методу до класифікації видів забруднень та щодо перенавчання сформованої моделі класифікації.

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

Враховуючи рівень виконання та забезпечення усіх необхідних вимог, робота може бути допущена до захисту. Рекомендована оцінка *добре*.

Рецензент

*зас. проф. АКИТА Р. Ш. В. Меремлюк*



**ВІДГУК НАУКОВОГО КЕРІВНИКА**  
**на кваліфікаційну роботу магістра**

студента *гр. КНм-22-1 Морського Олександра Олексійовича*

за темою Метод виявлення забруднень навколишнього середовища на основі супутникових зображень

**1. Актуальність теми**

Загроза забруднення навколишнього середовища для здоров'я людей і екосистем є серйозною проблемою. Викиди шкідливих речовин, незаконні сміттєзвалища та інші джерела забруднення мають значний вплив на якість повітря, води та ґрунту. Завдяки передовим супутниковим технологіям отримали можливість одержати зображення з великих територій і отримувати дані в режимі реального часу. Ця доступність відкриває широкі можливості для ефективного використання супутникових даних у виявленні джерел забруднення. В роботі розроблена система виявлення забруднень навколишнього середовища на основі супутникових зображень, яка є актуальною задачею комп'ютерних наук

**2. Відповідність роботи предметній області Стандарту спеціальності 122 Комп'ютерні науки**

Згідно зі стандартом, що визначає предметну область, об'єктами вивчення та діяльності є математичні, інформаційні, імітаційні моделі реальних явищ, об'єктів, систем і процесів. Метою даної роботи є розробка методу для виявлення забруднень навколишнього середовища, використовуючи супутникові зображення. Під час вирішення цієї задачі були використані математичні моделі, методи та алгоритми для вирішення теоретичних і практичних завдань, пов'язаних з розробкою методів машинного навчання. Результати цієї роботи відповідають стандартам магістра у галузі комп'ютерних наук.

**3. Професійні та особистісні якості**

Під час виконання магістерської кваліфікаційної роботи Морський Олександр Олексійович продемонстрував високий рівень знань та навичок, вчасно та ефективно виконував поставлені завдання. Під час написання пояснювальної записки і розробки прикладного програмного забезпечення виявив високі компетентності та успішні результати в навчанні. Він успішно володіє професійними вміннями в галузі "Комп'ютерні науки".

#### 4. Ступінь самостійності під час виконання кваліфікаційної роботи

Одержані в роботі результати є наслідком особистої діяльності студента, який самостійно виконував усі поставлені задачі.

#### 5. Наукова новизна та оригінальність запропонованих підходів

Магістерська кваліфікаційна робота включає наукову новизну, яка полягає у вдосконаленні методу виявлення забруднень навколишнього середовища на основі супутникових зображень. Метод дозволяє автоматично виділяти забруднені та чисті ділянки на зображеннях, використовуючи параметри максимальної та мінімальної інтенсивності пікселів та площі забруднених ділянок. Його відмінність полягає у можливості точної ідентифікації та класифікації стихійних сміттєзвалищ і видів сміття на супутникових зображеннях. Результати роботи оприлюднені на науково-практичній конференції.

#### 6. Ступінь оволодіння методами дослідження

При реалізації кваліфікаційної роботи продемонстровано належний рівень компетентностей та володіння необхідними методами, методиками та технологіями предметної області комп'ютерних наук.

#### 7. Повнота та якість розкриття теми роботи

Тема роботи повною мірою обгрунтована та розкрита належним чином. Проведено аналіз відомих досліджень відповідно до обраної теми. Поставлені завдання реалізовані та розроблено програмне забезпечення для реалізації запропонованого метода.

#### 8. Логічність, послідовність, аргументованість, літературна грамотність викладення матеріалу

Структура роботи та послідовність викладення логічні та відповідають поставленій меті. Викладення матеріалу послідовне, аргументоване, літературно грамотне.

#### 9. Можливість практичного застосування кваліфікаційної роботи, окремих її частин

Розроблений у роботі метод може бути використаний в системах виявлення забруднень навколишнього середовища.

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

Враховуючи належний рівень виконання та забезпечення усіх необхідних вимог, робота може бути допущена до захисту. Рекомендована оцінка «добре».

Керівник



д.т.н., професор каф. КН Едуард МАНЗЮК