

НАЦІОНАЛЬНИЙ ТЕХНІЧНИЙ УНІВЕРСИТЕТ УКРАЇНИ  
«КИЇВСЬКИЙ ПОЛІТЕХНІЧНИЙ ІНСТИТУТ  
імені ІГОРЯ СІКОРСЬКОГО»

ФАКУЛЬТЕТ ПРИКЛАДНОЇ МАТЕМАТИКИ

КАФЕДРА СИСТЕМНОГО ПРОГРАМУВАННЯ І  
СПЕЦІАЛІЗОВАНИХ КОМП'ЮТЕРНИХ СИСТЕМ

«На правах рукопису»  
УДК 004.932

«До захисту допущено»

Завідувач кафедри СПСКС

\_\_\_\_\_ В.П.Тарасенко  
(підпис) (ініціали, прізвище)  
“ \_\_\_ ” \_\_\_\_\_ 2018р.

## Магістерська дисертація

на здобуття ступеня магістра

зі спеціальності 123 Комп'ютерна інженерія

Комп'ютерні системи та компоненти

на тему: Комп'ютерна система ідентифікації магістралей на супутникових зображеннях

Виконав (-ла): студент (-ка) II курсу, групи КВ-71мп

Кривоніс Артем В'ячеславович

Науковий керівник доцент кафедри, ктн, Орлова М.М.

Рецензент д.т.н., професор, професор кафедри ОТ Кулаков Ю.О.

Засвідчую, що у цій магістерській  
дисертації немає запозичень з праць інших  
авторів без відповідних посилань.

Студент \_\_\_\_\_  
(підпис)

НАЦІОНАЛЬНИЙ ТЕХНІЧНИЙ УНІВЕРСИТЕТ УКРАЇНИ  
«КИЇВСЬКИЙ ПОЛІТЕХНІЧНИЙ ІНСТИТУТ  
імені ІГОРЯ СІКОРСЬКОГО»

Факультет прикладної математики

Кафедра системного програмування і спеціалізованих комп'ютерних систем

Рівень вищої освіти – другий (магістерський)

Спеціальність 123 Комп'ютерна інженерія

Комп'ютерні системи та компоненти

ЗАТВЕРДЖУЮ

Завідувач кафедри СПСКС

\_\_\_\_\_ В.П.Тарасенко

(підпис) (ініціали, прізвище)

«\_\_» \_\_\_\_\_ 2018р.

**ЗАВДАННЯ**  
**на магістерську дисертацію студенту**  
Кривоносу Артему В'ячеславовичу

1. Тема дисертації Комп'ютерна система ідентифікації магістралей на супутникових зображеннях, науковий керівник дисертації Орлова Марія Миколаївна доцент кафедри СПіСКС, к.т.н., доцент

затверджені наказом по університету від «30» жовтня 2018 р. № 4030-с

2. Термін подання студентом дисертації 07 грудня 2018 р.

3. Об'єкт дослідження процесу розпізнавання автомагістралей на супутникових зображеннях високої роздільної здатності

4. Предмет дослідження системи розпізнавання автомагістралей та побудови графу доріг, використовуючи супутникові зображення високої роздільної здатності

5. Перелік завдань, які потрібно розробити

- систему та спосіб розпізнавання магістралей на супутникових зображеннях;
- систему та спосіб побудови графу доріг.

6. Перелік публікацій

- «Поєднання Machine Learning та VR», 20-th International Conference «System Analysis and Information Technology» SAIT – 2018;

– «Порівняльний аналіз методів ідентифікації об'єктів на зображеннях», XI конференція молодих вчених ПМК-2018-2. – 2018;

7. Дата видачі завдання 5 вересня 2017 р.

#### Календарний план

№ з/п	Назва етапів виконання магістерської дисертації	Термін виконання етапів магістерської дисертації	Примітка
1	Вивчення літератури за тематикою проекту	05.09.2017	
2	Аналіз існуючих рішень	20.01.2018	
3	Підготовка матеріалів першого розділу магістерської дисертації	09.03.2018	
4	Підготовка матеріалів другого розділу магістерської дисертації	30.04.2018	
5	Підготовка матеріалів третього розділу магістерської дисертації	10.09.2018	
6	Підготовка графічної частини дипломного проекту	16.10.2018	
7	Оформлення документації дипломного проекту	01.11.2018	
8	Попередній розгляд магістерської дисертації на кафедрі	26.11.2018	

Студент

\_\_\_\_\_

(підпис)

Кривоніс А.В.

(ініціали, прізвище)

Науковий керівник дисертації

\_\_\_\_\_

(підпис)

Орлова М.М.

(ініціали, прізвище)



## РЕФЕРАТ

**Актуальність теми.** Від сучасних систем навігації залежать ключові процеси багатьох систем. Все більше людей використовують навігаторні системи для того, щоб розрахувати дорогу до кінцевої точки найкоротшим маршрутом з урахуванням певних умов. Також це може бути критичним для різних рятувальних служб, щоб в системі навігації були актуальні дані.

На сьогоднішній день над Землею знаходяться близько 20-ти тисяч штучних супутників, і їх число збільшується з кожним роком. Серед цих супутників на орбіті є ті, які здатні надсилати зображення планети у високій роздільній здатності. Але карти досі будуються картографічними спеціалістами, які використовуючи спеціальне програмне забезпечення, будують магістралі на супутникових зображеннях. Такі системи називають геоінформаційними. Завдяки можливостям глобальної мережі Інтернет люди мають доступ до відкритих спільних карт і можуть поєднувати свої зміни на одній глобальній карті, але досі цей процес, на жаль не є автоматизованим.

Актуальним є питання розпізнавання магістралей на супутникових зображеннях для підвищення якості побудованих та пошкоджених маршрутів. Це представляє великий інтерес для моніторингу стану маршрутів та побудови нових.

**Мета і задачі дослідження.** Метою даної роботи є розробка системи розпізнавання автомагістралей та доріг на супутникових зображеннях, що дозволило б побудувати граф доріг на основі методів розпізнавання на супутникових зображеннях. Для досягнення поставленої мети в роботі вирішуються наступні задачі.

1. Аналіз сучасних методів та їх застосування для розпізнавання автомагістралей та будь-яких інших доріг на супутникових зображень.

2. Розробка системи та способу розпізнавання магістралей на супутникових знімках та побудови графу доріг на основі отриманого зображення розпізнавання, яка дозволила б використати її в геоінформаційних системах.
3. Дослідження та оцінка розробленої системи розпізнавання магістралей.

*Об'єктом дослідження є процеси розпізнавання автомагістралей, які використовують супутникові зображення високої роздільної здатності.*

*Предметом дослідження є системи розпізнавання автомагістралей та побудови графу доріг, що використовують супутникові зображення високої роздільної здатності.*

**Методи дослідження.** В роботі використовуються методи системного аналізу, теорії графів, а також методів моделювання.

**Наукова новизна одержаних результатів** полягає в наступному.

1. Проаналізовано методи розпізнавання та класифікації зображень. Проведено аналітичне порівняння функціональності штучних нейронних мереж для розпізнавання зображень.
2. Проаналізовано способи розпізнавання супутникових зображень для ідентифікації магістралей та доріг на основі штучних нейронних мереж.
3. Розроблено спосіб та систему розпізнавання автомагістралей на супутникових зображеннях, яка відрізняється від існуючих можливістю побудови графу магістралей, що дозволить використовувати її в сучасних геоінформаційних навігаційних системах.

**Практична цінність одержаних результатів** полягає в тому, що розроблений спосіб та система дозволяє виконувати автоматичне розпізнавання магістралей та доріг на супутникових зображеннях високої

роздільної здатності.

У результаті розроблено програмне забезпечення, задача якого полягає в тому, щоб розпізнавати на супутникових зображеннях наявність магістралей та створити граф доріг на основі розпізнаного зображення.

**Апробація роботи.** Основні положення і результати роботи були представлені на:

1. ІХ науковій конференції магістрантів та аспірантів «Прикладна математика та комп'ютинг» ПМК-2018 (Київ, 14-16 листопада 2018 р.).
2. 20-th International Conference «System Analysis and Information Technology» SAIT – 2018 (Київ, 21-24 травня 2018 р.)

**Публікації.** За тематикою проведених досліджень опубліковано 2 наукові праці, а саме тези доповідей на конференціях.

**Структура та обсяг роботи.** Магістерська дисертація складається зі вступу, чотирьох розділів, висновків та додатків.

У вступі подано загальну характеристику роботи, зроблено оцінку сучасного стану проблеми, обґрунтовано актуальність напрямку досліджень, сформульовано мету і задачі досліджень, розкрито наукову новизну отриманих результатів та практичну цінність роботи.

У першому розділі проведено порівняльний аналіз методів сканування, розпізнавання супутникових зображень. Проаналізовано основні параметри та відмінні особливості.

У другому розділі описано способи розпізнавання магістралей на супутникових зображеннях, а саме, проаналізовано поведінку різних штучних нейронних мереж.

У третьому розділі представлено систему розпізнавання та побудови графу доріг для подальшого використання в сучасних системах навігації.

У четвертому розділі наведені практичні результати, що підтверджують запропоновані автором рішення.

Представлені результати отримання графу доріг з використанням штучних нейронних мереж на базі супутникових зображень високої

роздільної здатності.

У висновках проаналізовано результати магістерської роботи, одержані в результаті проведених досліджень.

**Ключові слова:** геоінформаційні системи, штучні супутники Землі, дистанційне зондування Землі, штучні нейронні мережі, розпізнавання зображень, супутникові зображення, граф доріг.

## ЗМІСТ

ЗМІСТ .....	1
ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ, СКОРОЧЕНЬ І ТЕРМІНІВ .....	9
ВСТУП .....	10
РОЗДІЛ 1. ОГЛЯД МЕТОДІВ ОТРИМАННЯ ТА ОБРОБКИ СУПУТНИКОВИХ ЗОБРАЖЕНЬ .....	12
1.1 Сучасні способи отримання супутникових зображень. ....	12
1.2 Методи дистанційного зондування Землі.....	13
1.2 Системи дистанційного зондування Землі .....	14
1.4 Методи фотозйомки .....	15
1.4.1 Сканерні зйомки.....	16
1.4.2 Радарні зйомки .....	19
1.4.3 Теплові зйомки.....	21
1.4.4 Спектрометричні зйомки.....	23
1.4.5 Лідарні зйомки .....	24
1.5 Згорткові штучні нейронні мережі .....	25
1.8 Архітектура LinkNet .....	29
1.9 Порівняння методів.....	31
Висновки до розділу 1 .....	35
РОЗДІЛ 2. РОЗПІЗНАВАННЯ МАГІСТРАЛЕЙ НА СУПУТНИКОВИХ ЗОБРАЖЕННЯХ ТА ПОБУДОВА ГРАФУ ДОРІГ .....	36
2.1 Методи навчання штучних нейронних мереж.....	36
2.2 Навчання нейронної мережі розпізнавання супутникових зображень ..	38
2.2 Пошук оптимальних параметрів та перенавчання.....	42
2.3 Спосіб створення моделі розпізнавання автомагістралей .....	47
2.3.1 Модель Inception v3 .....	47
2.3.2 Модель ResNet.....	56
2.4 Граф доріг .....	59
2.5 Заданя векторного відображення на картах .....	61
РОЗДІЛ 3. ОПИС РОЗРОБЛЕНОЇ СИСТЕМИ .....	67
3.1 Модуль розпізнавання супутникового зображення .....	67
3.2 Модуль побудови графу доріг .....	71

	8
Висновки до розділу 3 .....	74
РОЗДІЛ 4. АНАЛІЗ РОЗРОБЛЕНОЇ СИСТЕМИ РОЗПІЗНАВАННЯ МАГІСТРАЛЕЙ.....	75
4.1 Оцінка точності розпізавання автомагістралей.....	75
4.2 Оцінка часу на розпізнавання автомагістралей.....	77
4.3 Оцінка точності побудови графу доріг.....	78
ВИСНОВКИ .....	81
СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ .....	82

## ДОДАТКИ

Додаток 1. Фрагмент лістингу програмного коду

Додаток 2. Публікації за темою роботи

## ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ, СКОРОЧЕНЬ І ТЕРМІНІВ

APLS	Average Path Length Similarity – довжини шляху середньої схожості
CNN	Convolutional Neural Network – згорткові нейронні мережі
FC	Fully Connected Layer – шар повного поєднання
FN	False Negative – хибно негативний результат
FP	False Positive – хибно позитивний результат
IoU	Intersection over Union – перехрестне об'єднання
iIoU	instance-level Intersection over Union – екземплярний рівень перехрестного об'єднання
lr	learning rate – рівень навчання
ReLU	Rectified Linear Units – лінійні одиниці вилучення
TP	True Positive – правильно позитивний результат
ГІС	Геоінформаційна система
ДЗЗ	Дистанційне зондування Землі
ІЧ	Інфрачервоний
КЗ	Космічні Знімки
РЛБО	Радіолокатори Бічного Огляду
ШСЗ	Штучний Супутник Землі

## ВСТУП

Розвиток космічної галузі надає людству новий рівень отримання інформації. Кожного року на орбіті лише нашої планети збільшуються кількість супутників, які в режимі онлайн дозволяють отримувати актуальні дані про Землю. Все частіше синоптики користуються зображеннями з космосу, для прогнозу погоди чи стихійних лих. Проблеми глобального потепління не можуть бути досконально дослідженими якби не сотні космічних апаратів, які надсилають в центри показники температури в атмосфері. А що до обробки супутникових зображень, вона до сьогодні розпізнається лише людьми. Хоч і людство навчилось отримувати високоякісні зображення зі супутників, але і досі, всі ці зображення переглядаються в ручному режимі. Тому, проблема розпізнавання таких зображеннях є актуальною в теперішній час.

Поява високоякісних оптичних супутникових зображень, таких як IKONOS або Quickbird, відкриває нові можливості для розпізнавання автомагістралей. Перевагою таких даних над аерофотознімками є те, що вони практично доступні у всьому світі, радіометричним дозволом розміром в 11 біт, та у 4 спектральних смугах. Геометрична роздільна здатність 1 м для IKONOS і 0,6 м для Quickbird гірше, ніж для аерофотозйомки, але для цілей розпізнавання доріг у багатьох випадках все-таки достатній. Всесвітня наявність даних дає можливість виробляти топографічні бази даних практично для будь-якого регіону Землі, наприклад, для військових цілей та попередження або полегшення стихійних лих. В даний час виконується витяг із зображень в основному спеціалістами і це призводить до втрати часу. Щоб подолати це вузьке місце, необхідні автоматичні засоби.

Одним із рішень автоматизації даної задачі розпізнавання є використання штучних нейронних мереж. Штучна нейронна мережа - це математична модель, а також її програмна та апаратна реалізація,

побудовані за принципом функціонування біологічних нейронних мереж - мереж нервових клітин живого організму.

Сучасні обчислювальні технології дозволяють побудувати нейронні мережі, які будуть здатні розпізнавати зображення, та класифікувати його, аналізуючи не тільки об'єкти на цьому зображенні, а й певні патерни, які виходять з етапу навчання нейронної мережі.

Ця технологія дозволяє розпочати дослідження в розпізнаванні супутникових знімків, на наявність автомагістралей. Використовуючи різні підходи щодо створення нейронних мереж, можливо отримати із супутникового зображення маску магістралей. Дані отримані в результаті розпізнавання можуть використовуватись в подальшому різними системами. навігації та логістики. Це також дозволить отримати корисну інформацію для багатьох сфер інфраструктури.

## РОЗДІЛ 1. ОГЛЯД МЕТОДІВ ОТРИМАННЯ ТА ОБРОБКИ СУПУТНИКОВИХ ЗОБРАЖЕНЬ

Сучасні геоінформаційні та навігаційні системи набрали досить високого попиту за свою зручність в користуванні. Все більше водіїв використовують навігатори для прокладання маршрутів. Кожен з цих навігаторів для побудови маршруту потребує карту доріг. Для цього окремі компанії наймають людей, які розпізнають супутникові знімки та оновлюють маршрутні карти. Автоматизація цих процесів дозволить збільшити якість та найголовніше вчасність оновлення маршрутів для надання більш точнішої навігації.

### 1.1 Сучасні способи отримання супутникових зображень.

Розвиток геоінформатики та пов'язаних з ним технологій дозволило в цілком і сформувавши загальний підхід, як у побудові самих геоінформаційних систем (ГІС) так і моделі організації їх даних. З іншого боку, удосконалення технічних можливостей засобів реєстрації даних дистанційного зондування привело до істотного розширення міждисциплінарного простору областей знань, що досліджуються за допомогою ГІС.

Це дозволило вести роботу з реалізації системного підходу в розробці та застосуванні методів отримання та обробки даних Землі для рішення широкого обсягу конкретних тематичних задач. Дані дистанційного зондування Землі (ДЗЗ) є ефективним інструментом, що дозволяє оперативно і детально дослідити стан навколишнього середовища, використання природних ресурсів і отримувати об'єктивну картину світу.

Дистанційне зондування - це отримання інформації про земну поверхню включаючи розташовані на ній об'єкти, без безпосереднього контакту з нею шляхом реєстрації від неї електромагнітного випромінювання. Доступ до даного дистанційного зондування регулюється

політикою відкритого неба, відповідно до якого кожному користувачеві гарантується вільний доступ до всіх наявних даних на недискримінаційній основі. Основним міжнародним консультативним органом, створеним в 1984 році, для обміну інформацією, координацією та обговорення політики в області ДЗЗ, служить комітет по супутниковому спостереженню Землі.

Системи отримання та розповсюдження даних оперативного моніторингу базуються на чотирьох принципах:

- носіями знімальної апаратури, в даному випадку є штучні супутники Землі “ШСЗ”;
- обладнання дистанційного зондування;
- бортові засоби передачі даних на Землю по радіоканалу;
- наземних комплексів прийому цієї інформації її обробки и представлення користувачам.

## 1.2 Методи дистанційного зондування Землі

Методи дистанційного зондування засновані на тому, що будь-який об'єкт випромінює і відображає електромагнітну енергію відповідно до особливостей його природи. Відмінності в довжинах хвиль і інтенсивності випромінювання можуть бути використані для вивчення властивостей віддаленого об'єкта без безпосереднього контакту з ним.

Дистанційне зондування сьогодні - це різноманітність методів отримання зображень практично у всіх діапазонах довжин хвиль електромагнітного спектра, починаючи від ультрафіолетового до інфрачервоного, та радіодіапазону. А також різноманітну оглядовість зображень, від знімків з метеорологічних геостационарних супутників, охоплюючи практично цілу півкулю, до детальних аерозйомок ділянок в кількисот квадратних метрів.

## 1.2 Системи дистанційного зондування Землі

В даний час існує широкий клас систем ДЗЗ, що формують зображення досліджуваної поверхні [1]. В рамках даного класу апаратури можна виділити кілька підкласів, що розрізняються за спектральним діапазоном використаного електромагнітного випромінювання і за типом приймача реєстрованого випромінювання, а також за методом активного чи пасивного зондування:

- фотографічні і фототелевізійні системи;
- скануючі системи видимого та інфрачервоного діапазону (телевізійні оптико-механічні та оптико-електронні, скануючі радіометри та багатоспектральні сканери);
- телевізійні оптичні системи;
- радіолокаційні системи бічного огляду;
- скануючі радіометри.

У той же час триває експлуатація та розробка апаратури ДЗЗ, що орієнтована на отримання кількісних характеристик електромагнітного випромінювання, просторово-інтегральних або локальних даних. В даному класі систем ДЗЗ можна виділити кілька підкласів: нескануючі радіометри та спектрорадіометри, лідари (рис. 1.1).



Рисунок 1.1 - Системи дистанційного зондування землі

#### 1.4 Методи фотозйомки

Фотографічні знімки поверхні Землі отримують з пілотованих кораблів, орбітальних станцій або з автоматичних супутників. Відмінною рисою космічних знімків (КЗ) є високий ступінь оглядовості охоплення одним знімком великих площ поверхні. В залежності від типу застосованої апаратури і фотоплівок, фотографування може проводитися у всьому видимому діапазоні електромагнітного спектра, в окремих його зонах, а також в ближньому інфрачервоному діапазоні.

Масштаби зйомки залежать від двох найважливіших параметрів:

- висоти зйомки;
- фокусної відстані об'єктиву.

Космічні фотоапарати в залежності від нахилу оптичної осі дозволяють отримувати планові та перспективні знімки земної поверхні. В даний час використовується фотоапаратура з високим розширенням, що дозволяє отримувати КЗ з покриттям поверхні в 60% і більше. Спектральний

діапазон фотографування охоплює видиму частину ближньої інфрачервоної зони до 0.86 мкм.

Відомі недоліки фотографічного методу пов'язані з необхідністю повернення плівки на Землю і її обмеженим запасом на борту. Однак фотографічна зйомка в даний час найінформативніший вид зйомки з космічного простору. Оптимальний розмір відбитка 18x18 см, який, як показує досвід, узгоджується з фізіологією людського зору, дозволяючи бачити все зображення одночасно.

Для зручності користування з окремих КЗ, що мають перекриття, монтується фотосхеми, фотомозаїки або фотокарти з топографічною прив'язкою опорних точок з точністю 0.1 мм і точніше. Для монтажу фотосхем використовуються тільки планові КЗ.

Для приведення різномасштабного, зазвичай перспективного КЗ до планового, використовується спеціальний процес, який називається трансформуванням. Трансформовані КЗ використовуються для складання космофотосхем і космофотокарт і зазвичай легко прив'язуються до географічної сітки координат.

#### 1.4.1 Сканерні зйомки

В даний час для зйомок з космосу використовуються багатоспектральні сканерні системи, які також називають мультиспектральні оптико-механічні сканери, що встановлені на штучних супутниках Землі (ШСЗ) різного призначення [2].

За допомогою сканерів формуються загальне зображення, що складається з окремих послідовно одержуваних елементів зображень. Термін сканування – позначає розгортку зображення за допомогою скануючого елемента (коливаючогось або обертаючого дзеркала), що по елементно переглядає місцевість перпендикулярно руху носія і надсилає променевий потік в об'єктив і далі на точковий датчик, перетворюючи

світловий сигнал в електричний.

Цей електричний сигнал надходить на приймальні станції каналами зв'язку. Зображення місцевості отримують безперервно на стрічці, що складається зі смуг – сканів, складених окремими елементами – пікселями.

Сканерне зображення можна отримати у всіх спектральних діапазонах, але особливо ефективним є видимий і інфрачервоний (ІЧ) діапазони, при зйомці земної поверхні за допомогою скануючих систем формується зображення, кожному елементу якого відповідає яскравість випромінювання ділянки, що знаходиться в межах миттєвого поля зору.

Сканерне зображення – упорядкований пакет яскравості даних, переданих радіоканалами на Землю, які фіксуються на магнітну стрічку цифровому вигляді і потім можуть бути перетворені в кадрову форму (рис. 1.2).

Найважливішою характеристикою сканера є кут сканування, огляду та миттєвий кут зору, від величини якого залежать ширина смуги і роздільна здатність зображення. Залежно від величини цих кутів сканери ділять на точні і оглядові.

У точних сканерів кут сканування зменшують до  $\pm 5^\circ$  а у оглядових збільшують до  $\pm 50^\circ$ . Величина роздільної здатності зображення при цьому обернено пропорційна ширині смуги.




Рисунок 1.2 – Схематичне зображення сканерних систем ДЗЗ

Одним з таких сканерів є сканер нового покоління, названий “тематичним картографом”, яким були оснащені американські ШСЗ “Landsat 5” та “Landsat 7” (рис. 1.3).

Сканер типу “тематичний картограф” працює в семи діапазонах з роздільною здатністю 30 м у видимому діапазоні спектра і 120м в інфрачервоному діапазоні.

Цей сканер дає великий потік інформації, обробка якої вимагає більшого часу, в зв'язку з чим сповільнюється швидкість передачі зображення (число пікселів на знімках досягає більш ніж 36 млн на кожному з каналів).




Рисунок 1.3 – Схематичне зображення супутника "Landsat 7"

Скануючі пристрої можуть бути використані не тільки для отримання зображень Землі, але і для вимірювання радіації – скануючі радіометри, і випромінювання – скануючі спектрометри.

#### 1.4.2 Радарні зйомки

Радіолокаційна (РЛ), або радарна зйомка - важливий вид дистанційних досліджень. Використовується в умовах, коли безпосереднє спостереження поверхні планет ускладнене різними природними умовами: щільною хмарністю, туманом тощо. Вона може проводитися в темний час доби, оскільки є активним видом отримання зображення.

Для радарної зйомки зазвичай використовуються радіолокатори бічного огляду (РЛБО), встановлені на літаках і ШСЗ. За допомогою РЛБО радіолокаційна зйомка здійснюється в радіодіпазоні електромагнітного спектра.

Суть зйомки полягає в надсиланні радіосигналу, що відбивається по

нормалі від досліджуваного об'єкта і фіксується на приймачі, встановленому на борту носія. Радіосигнал формується спеціальним генератором. Час повернення його в приймач залежить від відстані до досліджуваного об'єкта.

Цей принцип роботи радіолокатора, який фіксує різний час проходження зондуючого імпульсу до об'єкту і назад, використовується для отримання радіолокаційних знімків. Зображення формується плаваючою по рядку світловою плямою. Чим далі об'єкт, тим більше часу потрібно на проходження відбитого сигналу до його фіксації електронно-променевою трубкою, поєднаною зі спеціальною кінокамерою.

При дешифруванні радарних знімків слід враховувати тон зображення і його текстуру. Тонові неоднорідності радіолокаційного знімка залежать від літологічних особливостей порід, розміру їх зернистості, стійкості процесам вивітрювання. Тонові неоднорідності можуть варіювати від чорного до світлого кольору.

Радіолокаційні знімки задані чорним тоном відповідають гладким поверхням, де, як правило, відбувається майже повне відображення надісланого радіосигналу. Наприклад, великі річки завжди мають чорний тон. Текстурні неоднорідності радіолокаційного зображення залежать від ступеня розділеності рельєфу і можуть бути тонкосітчатими, смугастими, масивними тощо.

Смугаста текстура радіолокаційного зображення, наприклад, характерна для гірських районів, складених часто шарами, де чергуються осадові та метаморфічні породи.

Особливо добре виходить на радіолокаційних знімках гідро-мережа. Вона дешифрується краще, ніж на фотознімках. Висока роздільна здатність радіолокаційної зйомки в районах, покритих густою рослинністю, відкриває широкі перспективи її використання.

Радарні системи бічного огляду з кінця 70-х років почали встановлювати на ШСЗ. Так, наприклад, перший радіолокатор був встановлений на американському супутнику "SeeSat", призначеному для

вивчення динаміки океанічних процесів. Пізніше був сконструйований радар, який було випробувано під час польотів космічного корабля "Шаттл". Інформація, отримана за допомогою цього радара, представляється у вигляді чорно-білих, кольорових синтезованих фото, телезображень або записів на магнітну стрічку. Роздільна здатність таких зображень – 40м.

Інформація піддається числовій та аналоговій обробці, такій як і сканерні знімки системи "Landsat". Це значною мірою сприяє отриманню високих результатів дешифрування. У багатьох випадках радіолокаційні знімки виявляються геологічно більш інформативними, ніж знімки супутників "Landsat" або інших оптичних сенсорів.

Найкращий результат досягається при комплексному дешифруванні матеріалів змішаних видів. Радіолокаційні знімки успішно використовуються для вивчення важкодоступних або недоступних територій Землі: пустель і областей, розташованих у високих широтах, а також поверхні інших планет.

#### 1.4.3 Теплові зйомки

Теплова зйомка (інфрачервона зйомка, зйомка в ІЧ діапазоні) – це реєстрація електромагнітного випромінювання об'єктів в тепловій інфрачервоній ІЧ області спектру і подання його у вигляді зображення. Теплове випромінювання, інтенсивність якого залежить від температури, може бути виявлено приймачами теплового випромінювання і перетворено в видиме зображення, представляє відмінності в температурі об'єктів. Теплова зйомка може здійснюватися як в денний, так і в нічний час.

При дистанційному зондуванні Землі в тепловому діапазоні використовуються вікна прозорості з довжиною хвилі 3-5, 8-14 мкм. У цьому діапазоні проявляється власне випромінювання об'єктів земної поверхні.

Перші системи реєстрації теплового випромінювання були створені в 1930 рр. і знайшли застосування в період другої світової війни для виявлення військових та промислових об'єктів. Перші теплові знімки земної поверхні були отримані з метеорологічних супутників “TIROS”, “Метеор”, які давали теплові зображення Землі з просторовою роздільною здатністю близько 10 км.

В останні десятиліття з'явилася апаратура для багатозональної та гіперспектральної зйомки, які охоплюють також і тепловий діапазон (“ASTER”, “MODIS”) встановлена на супутниках “Terra” та “Aqua”, а просторова роздільна здатність теплових знімків підвищилась до 1 км у метеорологічних системах “MODIS” та до 60-90 м. у ресурсних штучних супутниках Землі “Landsat ETM+” та “ASTER”.

Результати теплової зйомки поверхні Землі знаходять широке застосування в різних областях: від вивчення та прогнозування глобальних кліматичних процесів, енергетичного балансу на основі моніторингу та картографії теплових полів Землі, температури морської поверхні, спостережень за вулканічною активністю, визначенням складу гірських порід і пошук корисних порід, виявлення джерел спалахів та моніторингу лісових пожеж, до визначення стану підземних теплових мереж, картографування та діагностики стану нафти та газопроводів.

В останні роки все більш широке розповсюдження отримує вивчення впливу “теплових островів” міських територій Urban heat island, контроль промислових викідів.

Таким чином, інфрачервона або тепла зйомка заснована на виявленні теплових аномалій шляхом фіксації теплового випромінювання об'єктів Землі, обумовленого ендегенним теплом або сонячним випромінюванням.

Вона широко застосовується в геології та геоінформаційних системах. Температурні неоднорідності поверхні Землі виникають в результаті неоднакового нагрівання різних її ділянок поверхні.

#### 1.4.4 Спектрометричні зйомки

Спектрометрична зйомка проводиться з метою вимірювання відбивної здатності гірських порід. Знання значень коефіцієнта спектральної яскравості гірських порід розширює можливості геологічного дешифрування, надає йому велику достовірність.

Гірські породи мають різну відбивну здатність, тому відрізняються величиною коефіцієнта спектральної яскравості.

Спектрометрична зйомка може бути трьох видів:

- мікрохвильова (0.3 см – 1.0 м), яка є універсальною, оскільки виключає вплив атмосфери;
- теплова або ІЧ (0.3 – 1000 мкм), яка виявляє температурні неоднорідності за енергетичною яскравістю об'єктів;
- спектрометрія видимого і близького ІЧ спектру випромінювання; (0.3 – 1,40 мкм), яка фіксує спектральний розподіл відбивного радіаційного випромінювання.

Геологічні об'єкти відображаються на КЗ з різним ступенем контрасту, залежним від їх спектральних особливостей (рис. 1.4).

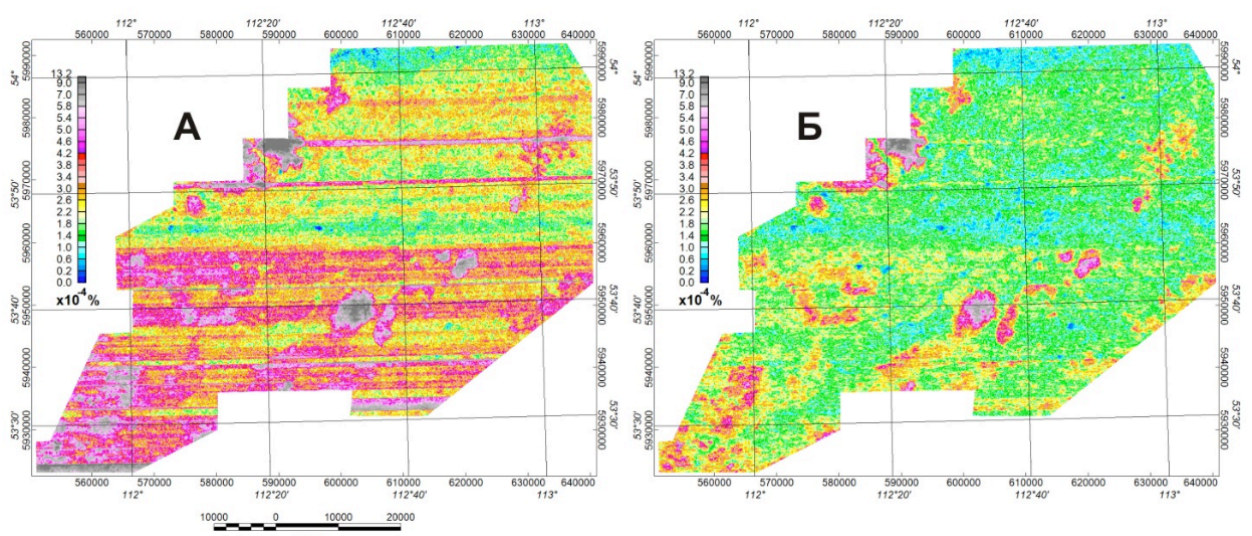


Рисунок 1.4 – Приклад карти спектрометричної зйомки

Робота зі складання бази даних про спектральні характеристики гірських порід надзвичайно містка. Для того щоб її виконати, необхідно зробити спектрометричні вимірювання гірських порід, а також інших ландшафтних об'єктів, на різних відстанях, в різні пори року на ділянках з різним ступенем відкритості.

Ці дані, однак, є абсолютно необхідними для систем автоматичного пошуку і розпізнавання об'єктів, в тому числі і екологічного змісту. В даний час збільшення граничних контрастів досягається за рахунок використання багатозональних знімків, отриманих у відносно вузьких зонах спектра.

#### 1.4.5 Лідарні зйомки

Лідар (LIDAR – Light Identification, Detection and Ranging) – технологія отримання та обробки інформації про віддалені об'єкти за допомогою активних оптичних систем, які використовують явища відбиття світла і його розсіювання в прозорих і напівпрозорих середовищах.

Лідар, як прилад, представляє собою активний далекомір оптичного діапазона. Скануючі лідари в системах машинного зору формують двовимірну або тривимірну картину навколишнього простору.

Атмосферні лідари здатні не тільки визначати відстані до непрозорих цілей що відбивають сигнал, а й аналізувати властивості прозорого середовища, розсіює світло.

Різновидом атмосферних лідарів є доплеровські лідари, які визначають напрямок і швидкість переміщення повітряних потоків в різних шарах атмосфери.

Лідарна зйомка є активною і заснована на безперервному відбитті сигналу від поверхні, що підсвічується лазерним монохроматичним випромінюванням з фіксованою довжиною хвилі.

Частота випромінювача налаштовується на резонансні частоти поглинання скануючого компонента, наприклад, поверхневого метану, так

що в разі його помітних концентрацій, співвідношення відбиття в точках концентрування і поза ними будуть різко підвищеними.

Фактично, лідарна спектроскопія – це геохімічна зйомка поверхневих шарів атмосфери, орієнтована на виявлення мікроелементів або їх з'єднань, що концентруються над сучасно активними геоекологічними об'єктами.

Пристрої лідарної зйомки встановлюються на низьковисотних штучних супутниках Землі.

### 1.5 Згорткові штучні нейронні мережі

Згорткові нейронні мережі (Convolutional Neural Network або CNN) клас штучних нейронних мереж, що використовуються для розпізнавання образів шляхом перетворення вихідного зображення через шари до класів. CNN був створений аналізуючи роботу мозку з розпізнавання зображень.

Щоразу, коли людина бачить щось власними очима, активізується серія шарів нейронів, і кожен шар буде виявляти набір таких функцій, як лінії, краї зображення. Високий рівень шару буде виявляти більш складні функції, щоб визначити загальну картину зображення.

Згорткові нейронні мережі складаються з двох шарів: шари вивчення особливостей (Conv, ReLU, Pool) та шарів класифікації (FC і softmax).

Conv або Згортковий шар є основним блоком згорткових нейронних мереж. Параметри шару складаються з набору фільтрів навчання (або ядер), які мають невелике вікно огляду, але простягаються через все вхідне зображення.

Під час прямого переходу кожен фільтр згортається по ширині та висоті вхідного зображення, обчислюючи точковий продукт між записами фільтра та входом і створюючи 2-мірну карту активації цього фільтра.

В результаті мережа навчає фільтри, які активуються, коли вони виявляють певний тип функції в деякій просторовій позиції на вході.

Накладання карт активації для всіх фільтрів вздовж розміру глибини

формує повний об'єм виходу згорткового шару.

Таким чином, кожен запис у вихідному томі можна інтерпретувати як висновок нейрона, який дивиться на невелику область вхідного сигналу і розподіляє параметри з нейронами на тій самій карті активації (рис 1.5)

Шар ReLU (Rectified Linear Units лінійні одиниці вилучення) застосовує функцію активації без насичення. Це підвищує нелінійні властивості функції вивчення особливостей, не впливаючи на краєфікаційні шари рівня згортки.




Рисунок 1.5 – Схематичне зображення архітектури Conv шару

Інші функції також використовуються для збільшення нелінійності, наприклад, насичуючої гіперболічної дотичної та сигмоїдної функції. ReLU часто віддає перевагу іншим функціям, тому що він навчає нейронну мережу в кілька разів швидше без суттєвої втрати точності узагальнення.

Шар об'єднання є важливою концепцією CNNs, його функція полягає в тому, щоб поступово зменшувати просторові розміри в згорткових шарах. Загально прийнятою є практика чередування декількох згорткових шарів та шару об'єднання. Це дозволяє зменшити кількість параметрів мережі.

Існує декілька нелінійних функцій для здійснення об'єднання, серед

яких найбільш часто зустрічається максимальне об'єднання. Він розділяє вхідне зображення на набір прямокутників що не пересікаються між собою і для кожного такого субрегіону виводить максимум.

Інтуїція полягає в тому, що точне місце розташування об'єкта є менш важливим, ніж його грубе розташування щодо інших функцій. Ущільнювальний шар служить для поступового зменшення просторового розміру представлення, для зменшення кількості параметрів та обсягу обчислень в мережі, а отже, і для контролю за перенавчанням.

Загально прийнято періодично добавляти шар об'єднання між послідовними конволюційними шарами в архітектурі CNN. Операція об'єднання забезпечує іншу форму інваріантності перекладу.

Шар повного поєднання (Fully Connected Layer або FC) – це шари за допомогою яких здійснюється міркування високого рівня в нейронній мережі.

Нейрони у повністю з'єднаному шарі мають зв'язки з усіма активаціями попереднього шару, як це реалізовано в звичайних нейронних мережах. Отже, їх активацію можна обчислити за допомогою матричного множення.

Такий підхід дозволяє побудувати систему розпізнавання зображення використовуючи невеликі набори даних. Наприклад одним із таких наборів є CIFAR-10 [1], що налічує 60 тис зображень, поділених на класи тварин та транспортних засобів.

Використовуючи дану архітектуру нейронних мереж можна навчити класифікувати зображення розміром 32x32x3 пікселі. Сторивши архітектуру в декілька шарів Conv та шарів FC на виході (рис. 1.5), та натренувавши модель до похибки в 0.01% можна отримати хороші результати класифікації зображення (рис. 1.6).

Таким чином, технологія розпізнавання зображень на основі згортових нейронних мереж, використовуючи заготовлений набір даних CIFAR-10 дозволила збільшити якість розпізнавання, а також сегментації зображень.

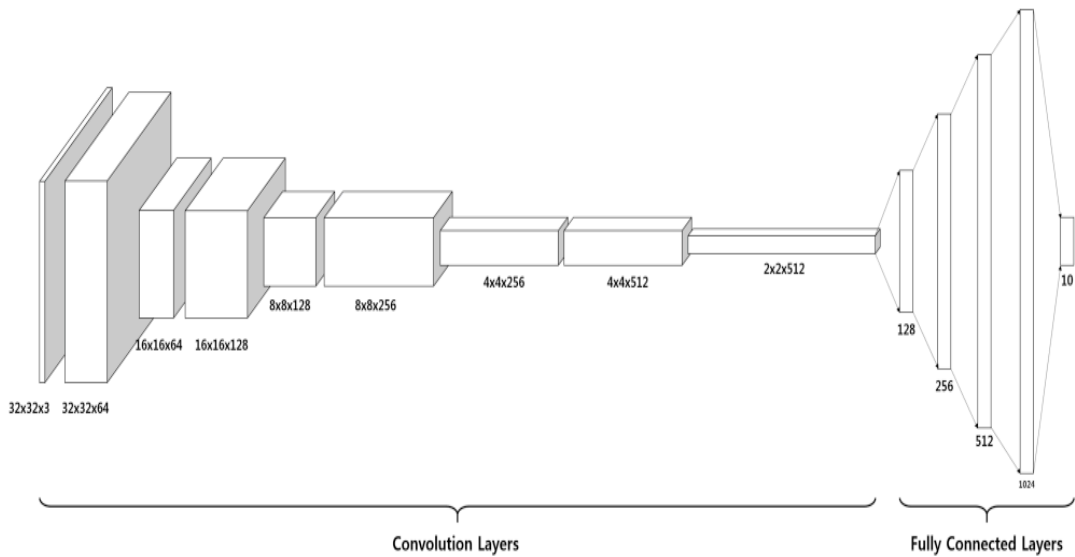


Рисунок 1.5 – Архітектура CNN для розпізнавання CIFAR-10

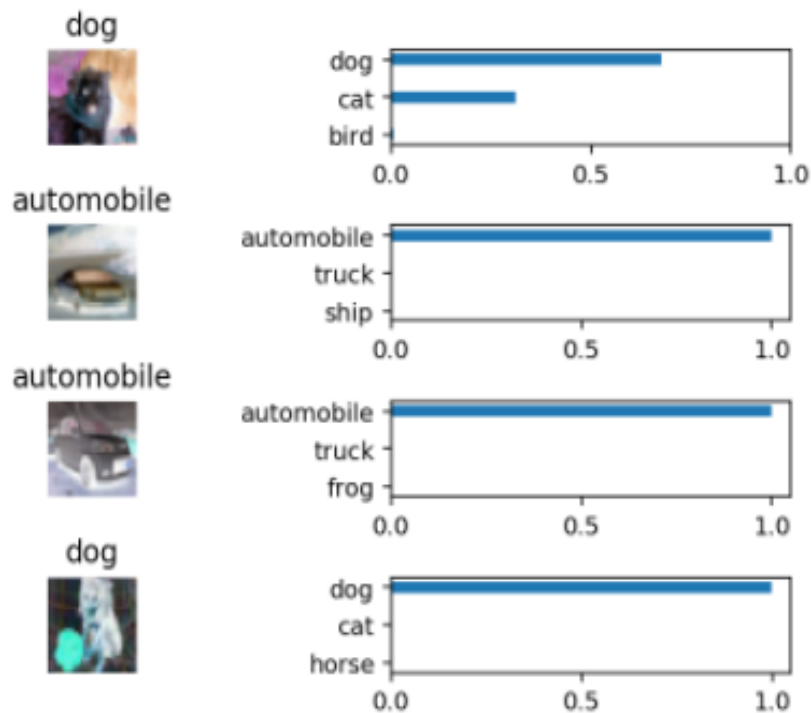


Рисунок 1.6 – Результати розпізнавання CIFAR-10

## 1.8 Архітектура LinkNet

Архітектура LinkNet є однією з передових архітектур штучних нейронних мереж для розпізнавання зображення, яка може використовуватись в системах автоматичного керування автомобілями чи для доповненої реальності [3].

Особливості LinkNet полягають в тому, щоб використовувати серію блоків кодера та декодера, для того щоб розбити зображення та знову його зібрати, перш ніж передавати його кільком кінцевими згортковими шарами. Структура мережі була розроблена для мінімізації кількості параметрів, щоб сегментація могла бути здійснена в режимі реального часу.

Архітектура штучної нейронної мережі складається з декількох блоків кодєрів та декодерів (рис. 1.7). Де Initial Block є блоком вхідної обробки зображення що розпізнається. Блок складається з шарів Pool та Conv.

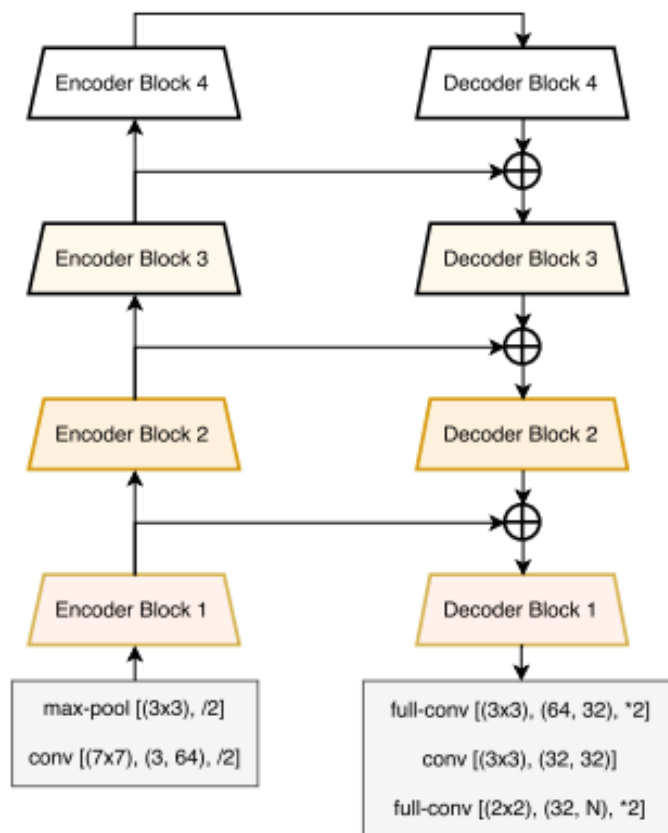


Рисунок 1.7 – Архітектура LinkNet для розпізнавання зображень

Кожен з блоків кодерів, в свою чергу складається з декількох згорткових шарів Conv розміром вікна в 3x3 (рис. 1.8).

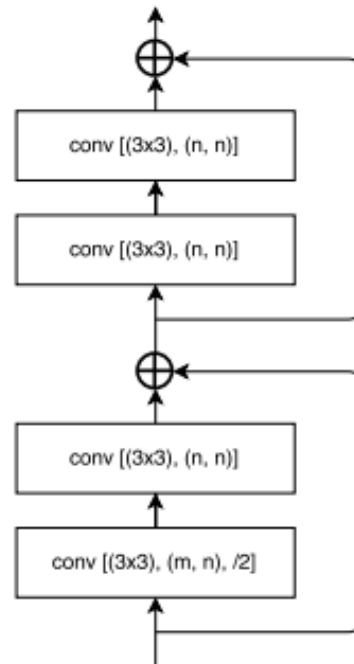


Рисунок 1.8 – Блок кодеру в LinkNet архітектурі

Блоки декодеру складаються з двох згорткових шарів та одного шару повного поєднання (рис. 1.9).

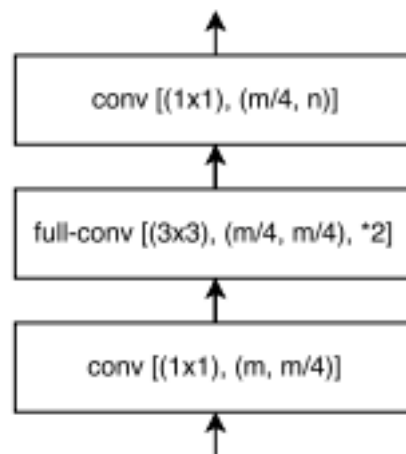


Рисунок 1.9 – Блок декодеру в LinkNet архітектурі

На відміну від існуючих архітектур нейронних мереж, які використовуються для сегментації, новий підхід архітектури LinkNet полягає в тому, як з'єднується кодер з декодером.

Використовуючи декілька операцій нехтування в кодерах, деякі просторові дані втрачаються. Важко відновити цю втрачену інформацію, використовуючи лише послідовний вихід кодерів. Тому кодер пов'язано з декодером через індекси згрупування, які не є тренувальними параметрами. Інші методи безпосередньо використовують вихід кодера та подають його на вхід декодера для виконання сегментації.

У цій архітектурі вхід кожного шару кодера поєднують на виході відповідного декодера. Цим методом намагаються відновити втрачену просторову інформацію, яка може бути використана декодером та його операціями для повторної вибірки. Крім того, оскільки декодер передає знання, отримані кодером на кожному рівні, декодер може використовувати менше параметрів.

## 1.9 Порівняння методів

Серед методів отримання супутникових зображень варто виділити найбільш популярний метод багатоспектральних, або мультиспектральні оптико-механічних систем – сканерних систем. Даний метод зйомки дозволяє отримати зображення високої роздільної здатності в усіх видимих спектрах. Саме таким методом отримують чітке зображення земної поверхні для подальшої візуальної обробки в геоінформаційних системах. Також даний метод зарекомендував себе у відомих системах ДЗЗ, таких як LandSat чи Sentinel.

Основними недоліками даного методу є можливість отримання поганого зображення, при значній хмарності, чи поганій освітленості ділянки. Метод радарної зйомки дозволяє обійти дані проблеми, але такі знімки не дають розуміння поверхні ділянки у виді сегментів. Цей метод дозволяє побудувати зображення в нічний час, але результат буде складний у дешифруванні та не дасть можливості подальшого аналізу автомагістралей.

Хоча сканерний метод має свої незручності, але сучасні штучні супутники землі дають достатньо варіантів однієї тієї ж ділянки, з різним ступенем освітленості та хмарності. Саме такі системи та їх зображення

дозволяють застосувати методи аналізу штучними нейронними мережами.

Аналізувати архітектуру LinkNet зі схожими існуючими архітектурами будемо за двома різними показниками:

1. Продуктивність з точки зору швидкості:
  - a. кількість операцій, необхідних для виконання одного проходження по мережі;
  - b. час, необхідний для виконання однієї передавальної передачі;
2. Продуктивності в плані точності на CamVid [4] набору даних, та набору даних Cityscapes [5].

Перевірка моделей нейронних мереж відбувалась на відеокартах від компанії NVIDIA (моделі як NVIDIA TitanX). В таблиці 1 наведено порівняння часу виведення для одного вхідного кадру з різною роздільною здатністю.

Як видно з наведених цифр в таблиці даних, штучна нейронна мережа LinkNet може обробляти зображення з високою роздільною здатністю на 10,5 кадрах в секунду використовуючи графічний процесор. Більше того, це може забезпечити продуктивність в реальному часі. Враховуючи здатність обробки в 640 x 360 пікселів з 30 кадрами на секунду, можна сказати, що мережа здатна розпізнавати зображення в пристроях автономного керування автомобілями.

Таблиця 1 – Результати порівняння архітектур нейронних мереж

Розмір зображення	480x320		640x360		1280x720	
	ms	fps	ms	fps	ms	fps
Архітектура						
CNN	69	14.6	289	3.5	637	1.6
SegNet	32	30.2	74	18.9	137	5.4
LinkNet	15	65.2	53	30.7	71	10.5

Кількість операцій визначає час проходження передачі будь-якої мережі, тому зменшення його є більш важливим, ніж зменшення кількості параметрів нейронної мережі. Ефективність підходу LinkNet полягає в набагато меншій кількості операцій з кадром та загальними параметрами штучної нейронної мережі.

Для порівняння штучних нейронних мереж використовується перехрестне об'єднання (intersection over union IoU) та екземплярний рівень перехрестного об'єднання (instance-level intersection over union iIoU) [6] як метрика ефективності замість використання піксельної точності.

Таблиця 2 – Результати точності розпізнавання

Архітектура ШНН	Будівлі	Дерева	Небо	Автомобіль	Дорожній знак	Дорога	Пішоходи	Огорожі	Стовби	Велосипеди	IoU	iIoU
CNN	74	78	95	82	55	95	67	51	35	86	68	51
SegNet	88	87	92	82	20	97	56	49	27	84	65	55
LinkNet	88	85	92	77	41	97	57	57	38	88	68	55

Набір даних складався з 5 000 підготовлених зображень. З яких 2975 були доступні в якості навчального набору, 500 зображень використовувались для перевірки навчання нейронних мереж, а решта 1525 були обрані для тестового набору оцінки точності нейронних мереж.

Результати розпізнавання та сегментації зображення показують що штучна нейронна мережа працює достатньо добре. Зліва наведені вхідні зображення, що розпізнаються.

Тестове зображення було сегментовано людиною, де різним кольорам відповідають різні класи сегментації, наприклад червоний колір відповідає

автомобілям. Розпізнаний результат доволі сильно співпадає з тестовим зображенням, що було відформатоване людиною. (рис. 1.10)

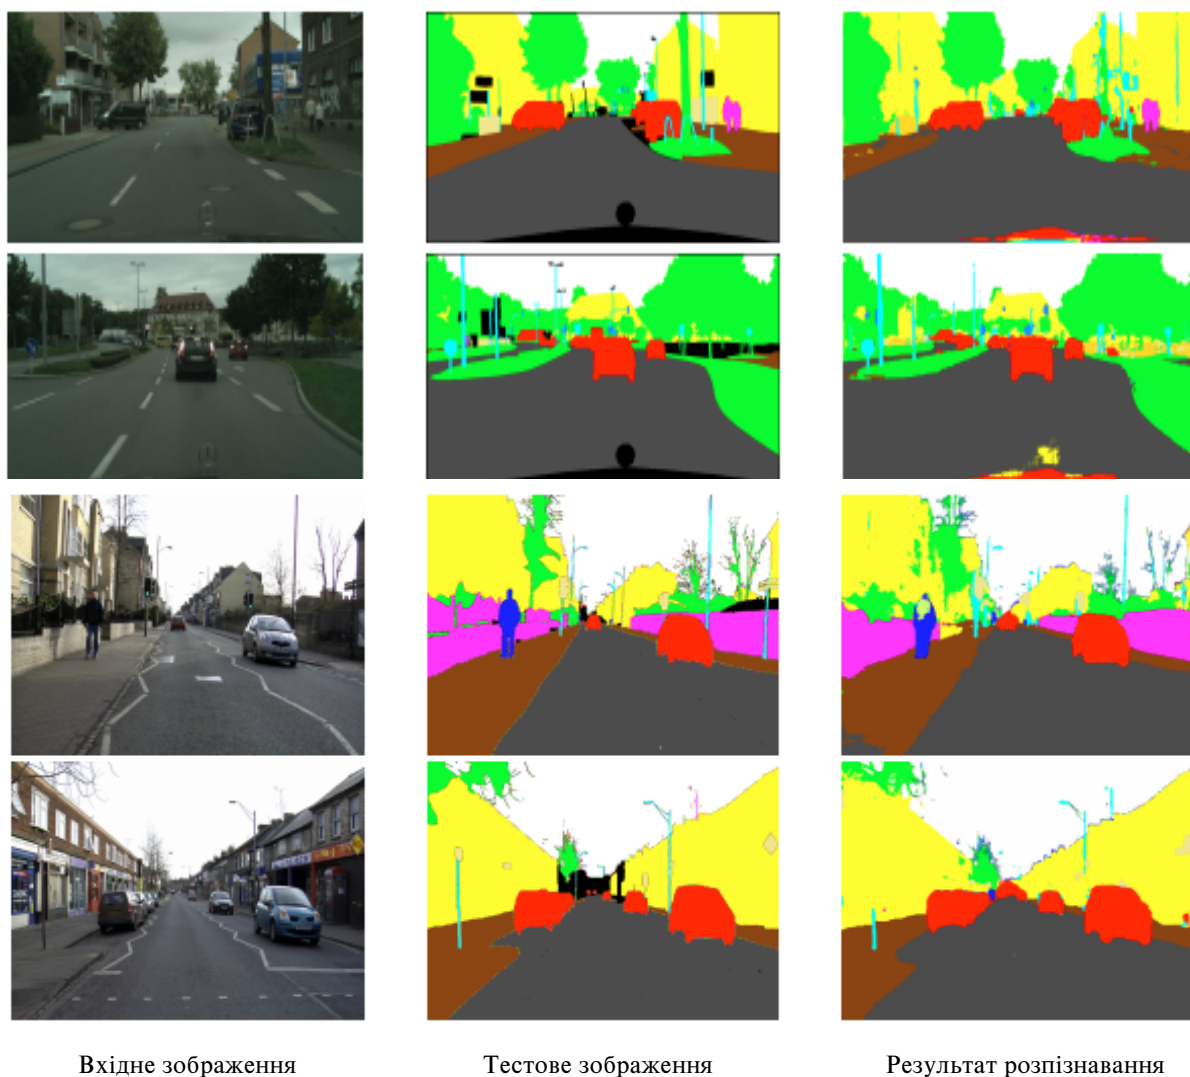


Рисунок 1.10 – Результати розпізнавання LinkNet

Таким чином проведено порівняння методів отримання супутникових знімків показав що сучасні системи дистанційного зондування Землі дозволяють отримувати зображення високої роздільної здатності про стан доріг та магістралей Землі. Також аналіз архітектур штучних нейронних мереж показав що зображення можливо сегментувати для виділення на ньому певних класів об'єктів.

## Висновки до розділу 1

1. Проведено аналітичний огляд методів отримання супутникових зображень та дистанційного зондування Землі (ДЗЗ), проаналізовано існуючі підходи до розпізнавання зображень використовуючи сучасні системи розпізнавання на базі штучних нейронних мереж.
2. Показано, що сучасні методи розпізнавання зображення здатні сегментувати вхідні дані на досить високому рівні базуючись на архітектурі LinkNet.
3. Показано основні особливості отримання зображень високої роздільної здатності використовуючи ДЗЗ для подальшого розпізнавання автомагістралей.
4. Наведено приклади, систем дистанційного зондування Землі, які здатні надавати зображення високої роздільної здатності, такі як Sentinel.
5. Проведено порівняння штучних нейронних мереж для розпізнавання та сегментації зображень.
6. Показано, що на сьогоднішній день залишається невирішеною задача автоматизації процесу ідентифікації магістралей та будь-яких інших доріг на супутникових зображеннях.

## РОЗДІЛ 2. РОЗПІЗНАВАННЯ МАГІСТРАЛЕЙ НА СУПУТНИКОВИХ ЗОБРАЖЕННЯХ ТА ПОБУДОВА ГРАФУ ДОРІГ

Для подальшої розробки системи потрібно обрати основну архітектурну модель штучної нейронної мережі та обрати формат даних для представлення результату. Розглянемо основні підходи розпізнаванню супутникових знімків високої роздільної здатності використовуючи штучні нейронні мережі.

### 2.1 Методи навчання штучних нейронних мереж

Перш за все для отримання робочої моделі штучних нейронних мереж її потрібно навчити. Ця властивість є ключовою в мережах, оскільки дає змогу на основі вибірки даних підвищити ефективність розпізнавання.

Процес підвищення якості розпізнавання відбувається за певними правилами в часі. За допомогою корегування інтерактивного процесу навчання, зміни синаптичних ваг та порогів активацій функцій збільшується якість розпізнавання.

Процес навчання – це процес в якому вільні параметри нейронної мережі налаштовуються через моделювання оточення, під яку мережа запрограмована. Тип навчання задається способом підлаштування цих параметрів. Дональд Гебб створив гіпотезу навчання, засновану на механізмі нейроплатичності, механізмі що вводить зміни поведінки на зміну середовища, її також назвали геббове навчанняє.

За допомогою алгоритму розпізнавання образів було створено перший перцептрон, комп'ютерну модель сприйняття інформації. Та навчено на розпізнавання через функцію диз'юнкції.

Навчання поділяють на декілька парадигм:

- кероване навчання;

- спонтане навчання;
- навчання з підкріпленням.

Кероване навчання (supervised learning) – вид навчання, при якому викростовується набір прикладів та відповідей, і має на меті пошук функції  $f(X) \rightarrow Y$  в дозволеному класі функцій, що відповідає цим прикладам. Тобто, створення такого відображення, на яке вхідні дані схожі.

Функцією обчислення похибки зазвичай є середньоквадратична похибка, в основі якої лежить зведення до мінімуму усереднену квадратичну похибку між результатом мережі та цільовим значенням  $y \in Y$ . Зведення до мінімуму цих витрат за допомогою алгоритмів зворотного поширення, називають керованим навчанням.

Спонтане навчання (unsupervised learning) – вид навчання штучних нейронних мереж, при якому на вхід дається певний набір даних  $X$  та функція витрат, якою може бути будь-яка функція від даних  $X$  та виходу мережі. Цілью навчання є зведення витрат до мінімуму.

Функція витрат залежить від виду предметної області моделі або задачі, що вона виконує, та наявних апріорних припущень (неявних властивостей моделі, її параметрів).

Задачі, що вписуються в парадигму спонтанного навчання, є зазвичай задачами оцінювання. Наприклад, задачі кластерування, оцінювання статистичних розподілів, фільтрування та стиснення.

Навчання з підкріпленням (reinforcement learning) – вид навчання, при якому зазвичай не надаються дані  $X$ , а породжуються взаємодією агента з середовищем. В кожний момент часу агент виконує певну дію, а середовище породжує нові спостереження, та миттєві витрати відповідно до якоїсь динаміки. Метою є визначення такої стратегії, яка зводить до мінімуму міру довготривалих витрат, наприклад, очікуванні супутні витрати. Динаміка середовища та довготривалі витрати для кожної зі стратегій є зазвичай невідомими, але їх можливо оцінити.

## 2.2 Навчання нейронної мережі розпізнавання супутникових зображень

Для навчання системи було обрано керування навчання, оскільки основною задачею штучної нейронної мережі є розпізнавання певних образів, тобто кластеризація автомагістралей на зображеннях.

Для навчання було створено набір даних, що складається з супутникових зображень. Набір даних складався з зображень місцевості доріг та автомагістралей. Поверхня була розділена на певні регіони шириною та довжиною в 100 м аби знизити розміри нейронної мережі (рис. 2.1).



Рисунок 2.1 – Приклад вхідного зображення для розпізнавання

Для розпізнавання використовувались лише трьохканальні зображення високої роздільної здатності. Це дозволило спростити процес навчання, а також суттєво знизити апаратне навантаження. Не менш важливим є те, що саме такі трьохканальні зображення стають легкодоступними для будь-якого регіону. Оскільки такі зображення краще розпізнаються і являються звичними для людського ока, підготовка навчального датасету дозволяє легше створювати відповідні маски доріг.

Маска доріг представляє собою двохканальне зображення, на якому чорним кольором задано фонові об'єкти, які не є основною досліджуваною метою, а білим кольором виділено дороги на зображенні (рис. 2.2).




Рисунок 2.2 – Маска доріг для вхідного зображення

Оскільки для навчання штучної нейронної мережі потрібне тестове зображення, було створено набір відповідних масок для кожного вхідного навчального та тестувального зображення, щоб мережа могла мати еталон, з яким порівнюється функція похибки розпізнавання.

Генерація масок доріг зайняла велику частину часу підготовки навчального набору даних, оскільки кожна маска була створена використовуючи програми для редагування зображення. Кожне навчальне та тестове супутникове зображення місцевості доріг та автомагістралей було оброблене програмою редагування зображення, де білим кольором виділялись дороги ширші 2 м.

Для того щоб модель могла оцінювати якість розпізнавання, вибрані зображення та відповідні маски були поділені на такі групи:

- навчальні дані;
- тестові дані;
- дані валідації.

Кожний з цих використаних наборів даних поєднує в собі три відповідні типи даних. Першим типом є вхідне супутникове зображення високої роздільної здатності. Другим важливим типом даних є зображенням чорно-білої маски відповідних доріг та магістралей.

В навчальному наборі даних модель використовує вхідне зображення і маску для навчання. В тестовому наборі модель робить припущення щодо розміщення доріг на зображенні та порівнює з відповідною маскою для того, щоб оцінити якість навчання. На етапі валідації модель лише оцінюючи вхідне зображення прогнозує маску доріг та оцінює реальну якість розпізнавання моделі.

Також до кожного з наборів було додано і декілька навчальних зображень з дорогами та стежками що були менше 2 м, аби модель не була перенавчена, тобто не знаходила лишні співпадиння (рис. 2.3, рис. 2.4).

Основною задачею навчання є знайти таку функцію розпізнавання,

щоб сумарна похибка передбачень для всіх можливих значень була б мінімальною. Зазвичай в процесі навчання, на кожній ітерації, оцінюється похибка нейронної мережі.



Рисунок 2.3 – Приклад доріг та стежок



Рисунок 2.4 – Приклад маски відповідних доріг та стежок

## 2.2 Пошук оптимальних параметрів та перенавчання

Одним з базових та ефективних методів знаходження відображення сутності даних, тобто знаходження функції розпізнавання, є метод градієнтного спуску.

Градієнтний спуск - це ітеративний алгоритм оптимізації першого порядку для пошуку мінімуму функції.

Градієнтом називають міру зростання або спаадання в просторі якоїсь величини на одиницю довжини (рис. 2.5). Операція градієнту перетворює пагорб (ліворуч) в поле векторів (праворуч). Напрямок в сторону зростання значення називають позитивним градієнтом, а протилежний напрямок, в сторону спадання значення – негативним.




Рисунок 2.5 – Приклад градієнту функції

Для знаходження місцевого мінімуму функції з використанням градієнтного спуску потрібно виконати кроки, пропорційні негативу градієнта функції у поточній точці.

Якщо замість цього вживаються кроки, пропорційні позитивному

градієнту, значення наближаються до локального максимуму цієї функції; то процедура називається градієнтним підйомом.

Градiєнтний спуск ґрунтується на спостереженні, що, якщо функція  $F(x)$  з множинними змінними визначена і диференційована в околі точки  $\mathbf{a}$ , то  $F(x)$  найшвидше зменшується, якщо він виходить з  $\mathbf{a}$  у напрямку негативного градієнта  $F$  на в  $\mathbf{a}$ ,  $-\nabla F(\mathbf{a})$

Цей процес добре ілюструється для двовимірної функції (рис. 2.6).




Рисунок 2.6 – Градієнтний спуск для двовимірної функції

Тут функція  $F$  вважається визначеною у просторі, а її графік має форму чаші. Сині криві є контурними лініями, тобто областями, на яких значення  $F$  є постійним. Червоними стрілками, що походять із точок, показується напрямок негативного градієнта в цій точці.

На зображені видно що градієнтне сходження приводить нас до дна

чаші, тобто до точки, де значення функції  $F$  мінімальне.

В завданнях навчання методом градієнтного спуску намагаються мінімізувати значення похибки моделі штучної нейронної мережі.

Оскільки очікувана похибка є необчислюваною величиною, тому найкраще наближення – це емпірична похибка, що враховується на доступних зразках на кожній з ітерацій.

Але слід зауважити, що при спробі максимізувати мінімізацію похибки можлива ситуація, що знайдена функція буде складною в обчисленні, та враховувати всі вхідні дані замість виділення загальної властивості поведінки даних.

Зазвичай такі функції виділяють як функції, що перенавчилися. Прикладом перенавчання є така функція в задачі класифікації даних, яка враховує всі вхідні дані, навіть ті, які є певною похибкою або шумом.

Маючи певний набір двох ознак (на зображенні це трикутники та крапки) в спробі підібрати найкращі параметри, штучна нейронна мережа будує складну функцію, яка враховує усі значення, навіть шкідливі для наближення (рис. 2.7).

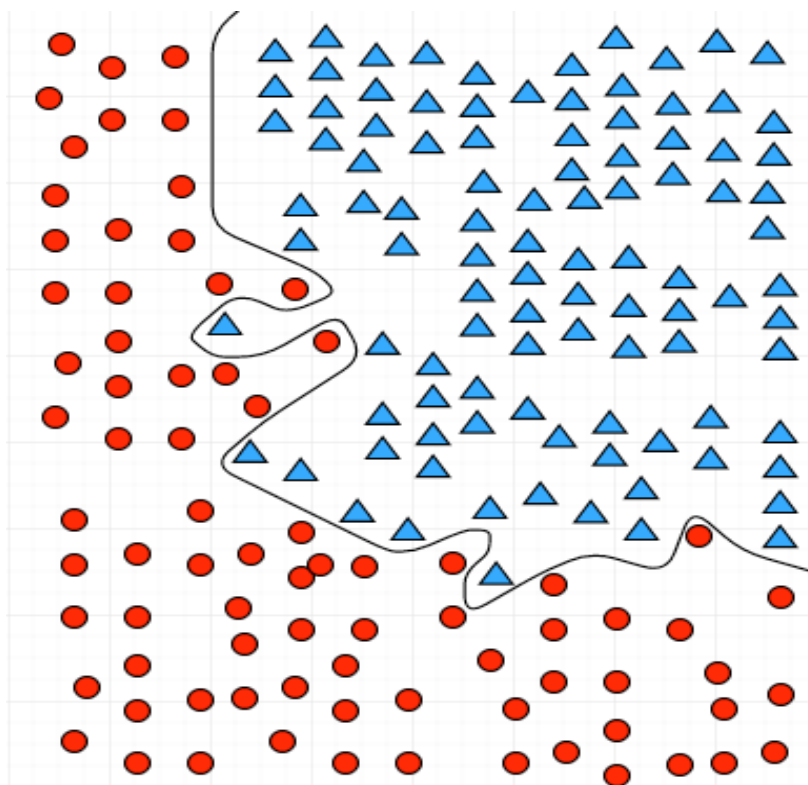


Рисунок 2.7 – Схематичне зображення перенавченої функції моделі

Але найкращим наближенням буде така узагальнена функція, зображена на прикладі, як чорна розмежувальна лінія (рис. 2.8).

При перенавчанні модель враховує і випадкову похибку, і шум на зображенні, замість взаємозв'язку, що лежить в основі даних. Цей результат досягається в зв'язку з тим, що існує певний критерій, який застосовується для тренування моделі, відрізняється від критерію оцінки ефективності моделі.

Щоб позбутись появи таких ситуацій, коли знайдена функція являється перенавченою, вводять певні обмеження на складність функції, а також намагаються скоротити похибки та зашумленість даних оцінюючи кореляцію вхідних даних.

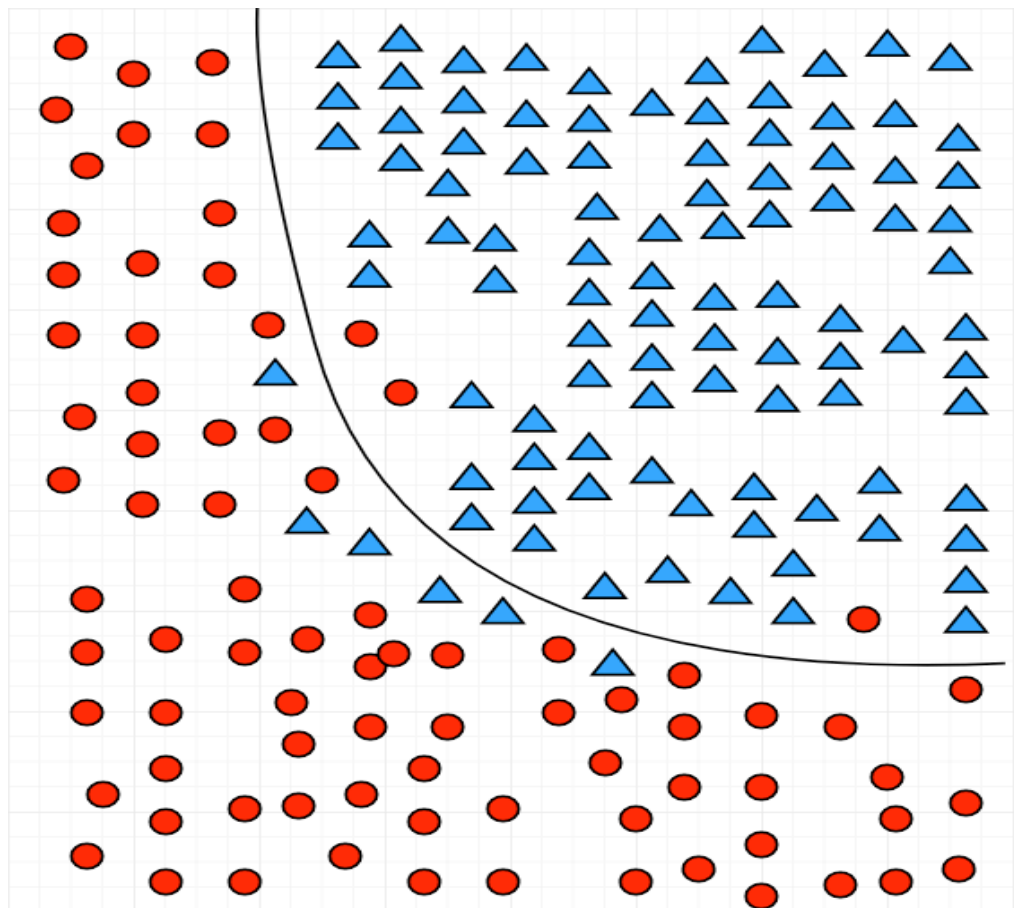


Рисунок 2.8 – Схематичне зображення коректної функції моделі

На етапі тренування моделі, зазвичай, намагаються максимізувати продуктивність розпізнавання. Тому для навчання нейронної мережі важливим є процес регуляризації та нормалізації вхідних даних.

Регуляризація означає додавання деякої додаткової інформації до процесу навчання, щоб уникнути перенавчання нейронних мереж. Оскільки основна задача в навчанні штучних нейронних мережах полягає в знаходженні функції, яка описує модель даних з найменшою похибкою, то очікувана сумарна похибка передбачень всіх значень виражається однією з функцій оцінки, наприклад, методом квадратів похибок.

В задачах навчання штучних нейронних мереж лише частина даних являється доступною для навчання, і часто ці дані є частково зашумленими. Таким чином, очікувана похибка являється необчислюваною величиною. Тому найкращими наближенням є емпірична похибка, що вираховується на базі  $N$  доступних зразків.

Без обмежень складності функціонального простору модель може бути навчена так, щоб відповідна їй функція проходила через кожну точку наявних даних. При наявності шуму модель може погіршуватись перенавчанням і видавати погані значення.

Тому регуляризація вводить штраф за включання зайвих областей функціонального простору, що використовується для побудови моделі і це може покращити узагальнення.

Для нормалізації навчального набору даних використовувався підхід усереднення значень. В навчальному наборі було знайдено максимальне  $max$  і мінімальне  $min$  значення кожного пікселя на зображеннях.

Для кожного зображення попіксельно застосовувалась функція усереднення  $avg(x)$ :

$$avg(x) = \frac{x - min}{max - min}.$$

Це дозволило позбутись зашумлених даних на зображенні та покращити якість процесу навчання.

## 2.3 Спосіб створення моделі розпізнавання автомагістралей

Автоматизація розпізнавання супутникового зображення та знаходження магістралей та доріг на ньому являється досить складною задачею. Для її вирішення було обрано декілька варіантів моделей на основі штучних нейронних мереж, які використовуються для розпізнавання та сегментації зображення та обрати найкращий варіант.

### 2.3.1 Модель Inception v3

Розглянемо архітектуру нейронної мережі для розпізнавання та кластеризації зображень **Inception v3**. Inception v3 – широко використована модель розпізнавання зображень, яка показала хорошу якість розпізнавання на наборі даних ImageNet [7].

З моменту створення ImageNet у 2012 р. мережа "AlexNet" успішно застосована до великої кількості різноманітних завдань комп'ютерного зору, наприклад, для виявлення об'єктів, сегментації, відеокласифікація, відстеження об'єктів тощо. Ці успіхи стимулювали нову лінію досліджень, що зосередили увагу на знаходження кращої згорткової нейронної мережі. Починаючи з 2014 року якість мережевих архітектур значно покращилась, завдяки використанню глибоких і ширших архітектур штучних нейронних мереж.

Глибокими називають ті архітектури мереж, які використовують велику кількість послідовно з'єднаних шарів, а широкими – архітектури що поєднують шари паралельно.

Подібні архітектури VGGNet і GoogLeNet отримали аналогічні результати високої продуктивності у 2014 році. Однією з цікавих закономірностей було те, що в показниках класифікації виграє підвищення якості в різних областях застосування. Це означає, що вдосконалення

архітектури в глибоких згорткових архітектурах штучних нейронних мереж можна використовувати для підвищення продуктивності більшості інших завдань, пов'язаних з комп'ютерним зором, які все більше залежать від високоякісних навчених візуальних особливостей. Також поліпшення якості розпізнавання в штучних нейронних мережах вплинули на нові домени додатків для згорткових мереж у випадках, коли функції AlexNet не могли конкурувати з ручними, розробленими рішеннями.

Хоча VGGNet має переконливу особливість архітектурної простоти, це потребує більших апаратних затрат: оцінка мережі вимагає багато обчислень. З іншого боку, початкова архітектура GoogLeNet також була розроблена для ефективної роботи навіть за суворих обмежень на пам'ять та обчислювальні можливості. Наприклад, архітектура GoogLeNet використовувала близько 7 мільйонів параметрів, що означало зменшення в 9 разів порівнюючи з попередньою архітектурою AlexNet, яка використовувала 60 мільйонів параметрів. Крім того, VGGNet використовує приблизно в 3 рази більше параметрів, ніж AlexNet.

Обчислювальна вартість Inception також набагато нижча, ніж VGGNet. Це дозволило використовувати мережі початкових сценаріїв у сценаріях великих даних, де величезна кількість даних повинна бути оброблена за розумною ціною або сценаріями, де пам'ять або обчислювальна потужність по суті є обмеженими, наприклад, у налаштуваннях мобільного зору.

Безумовно, можна пом'якшити частину цих проблем, застосовуючи спеціалізовані рішення для цільового використання пам'яті або оптимізувати виконання деяких операцій за допомогою обчислювальних покращень. Проте ці методи мають додаткову складність.

Тим не менш, складність архітектури Inception ускладнює внесення змін у мережу. Якщо архітектура набагато збільшена в ширину чи глибину, більша частина ефективності в обчисленнях може бути втрачена.

Це робить архітектуру більш складною до адаптування для нових випадків використання, зберігаючи при цьому ефективність. Наприклад,

якщо вважати за необхідне збільшити пропускну спроможність однієї моделі Inception, просте подвоєння кількості всіх розмірів блоків фільтра призведе до 4-кратного збільшення обчислювальної вартості та кількості параметрів.

Це може виявитись непомітним або нерозумним у багатьох практичних сценаріях, особливо якщо пов'язані з цим вигоди є незначними. Тим не менше, слід дотримуватися деяких керівних принципів щоб підтримувати високу якість моделей.

Початкова глибока конволюційна архітектура була представлена як GoogLeNet у 2015 р. Пізніше архітектура Inception була уточнена різними способами: спочатку шляхом запровадження пакетної нормалізації Inception v2. Додаткові ідеї факторизації в третій ітерації 2015 р., які далі будуть називати Inception v3 [8].

Перш за все розглянемо одне із нововведень архітектури Inception v3 була факторизаційна згортка. Метою факторизаційної згортки є зменшення кількості підключень параметрів без зниження ефективності мережі. Першим покращенням була заміна згортокових шарів  $5 \times 5$  на шари в  $3 \times 3$ . Використовуючи один шар в  $5 \times 5$  кількість параметрів буде дорівнювати 25, а для двох шарів  $3 \times 3$  - 18 (рис. 2.9).




Рисунок 2.9 – Схематичне зображення згортових шарів  $3 \times 3$

За допомогою цієї технології один з нових модулів Inception стає як представлено на рис. 2.10.

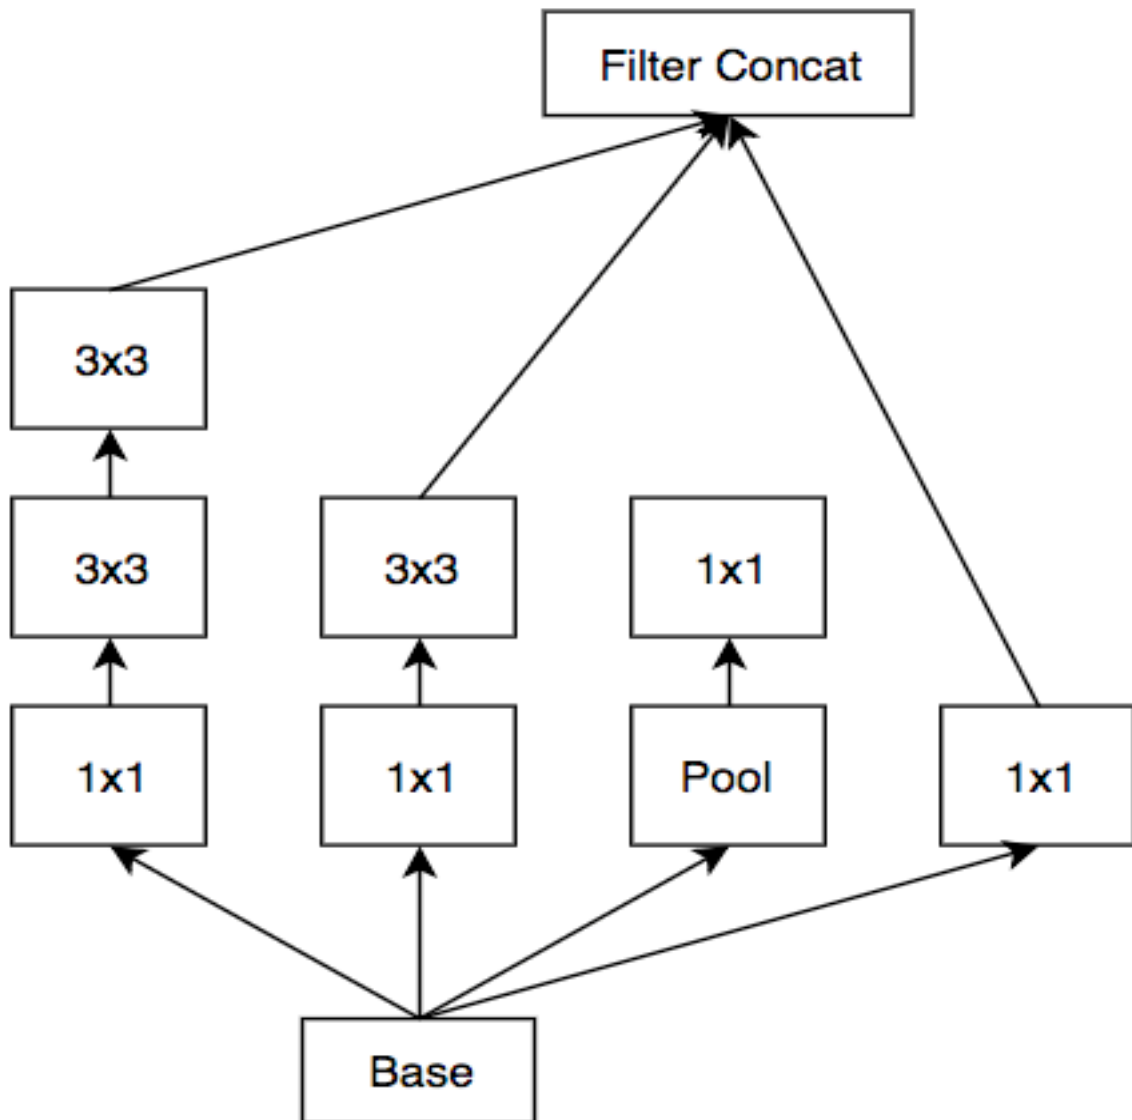


Рисунок 2.10 – Модуль А з використанням факторизаційної згортки

При цьому даний модуль в першій реалізації архітектури нейронної мережі Inception v1, так званої GoogLeNet використовується блок 5x5 замість 3x3 (рис. 2.11).

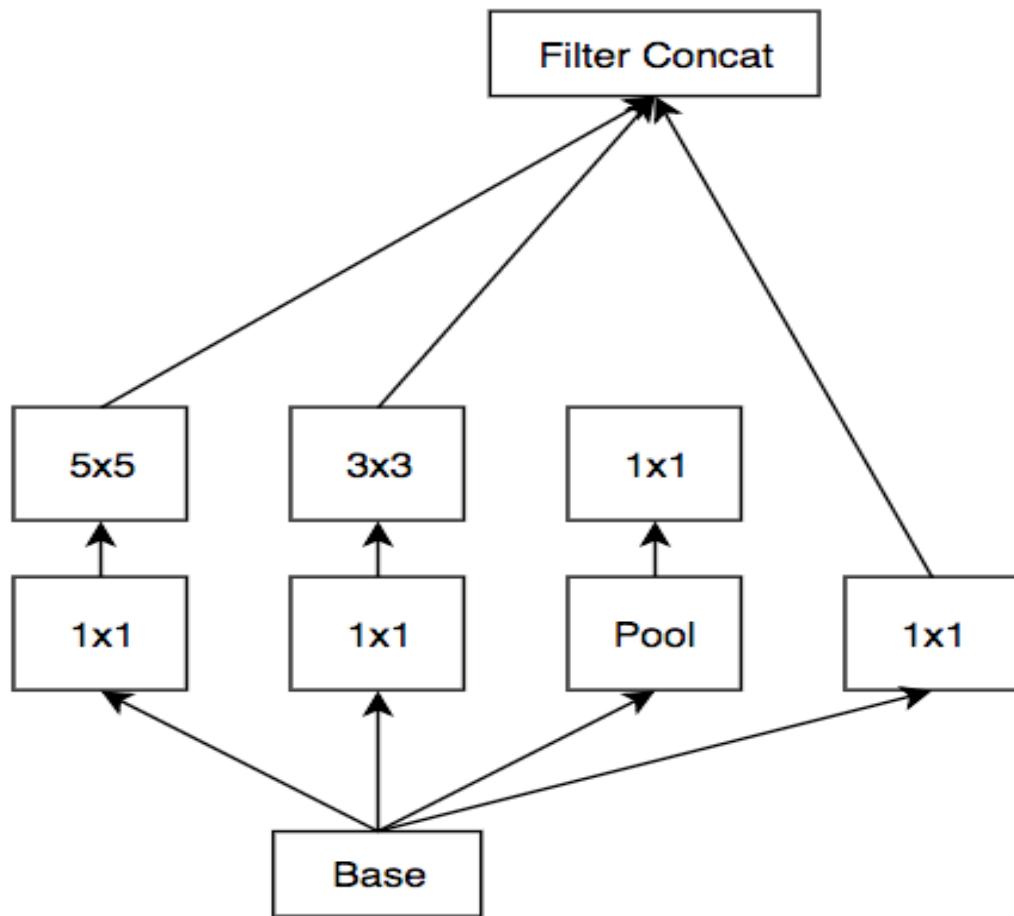


Рисунок 2.11 – Модуль А у архітектурі GoogLeNet

Факторизація в асиметричних згортках відбувається за рахунок асиметричних шарів.

Наприклад, один згортковий шар  $3 \times 3$  розбивається на два шари фільтрами  $3 \times 1$  та  $1 \times 3$ , що також зменшує кількість параметрів (рис 2.12).

Використовуючи такий підхід, ми отримуємо фільтр з шаром розміром  $3 \times 3$  а також два шари розміром  $1 \times 3$  та  $3 \times 1$ .

З цією технікою ми отримуємо значне скорочення в кількості параметрів та замінюємо деякі модулі новими, які зменшують кількість параметрів в мережі Inception v3 порівнюючи її з архітектурою першої версії GoogLeNet (рис. 2.13, рис. 2.14, рис. 2.15).




Рисунок 2.12 – Асиметричний згортковий шар

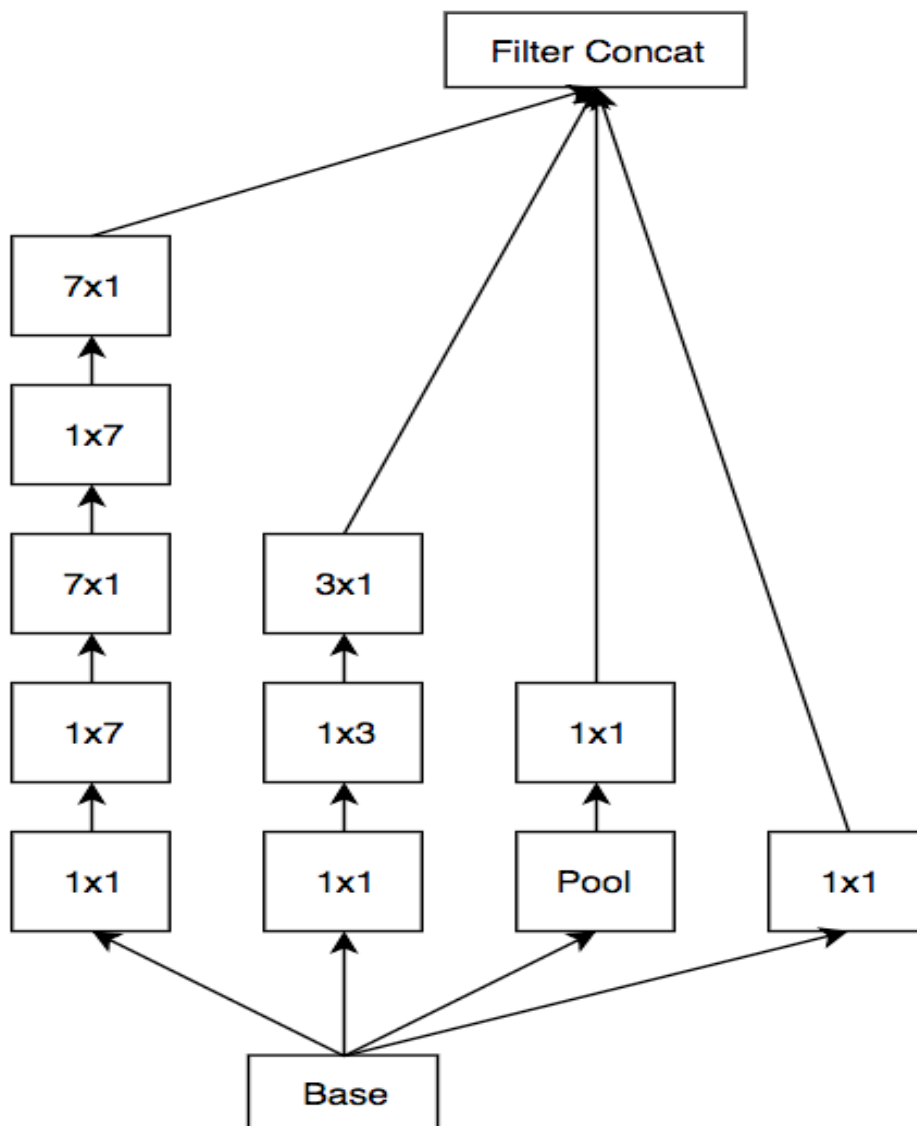


Рисунок 2.13 – Модуль В з використанням асиметричної згортки

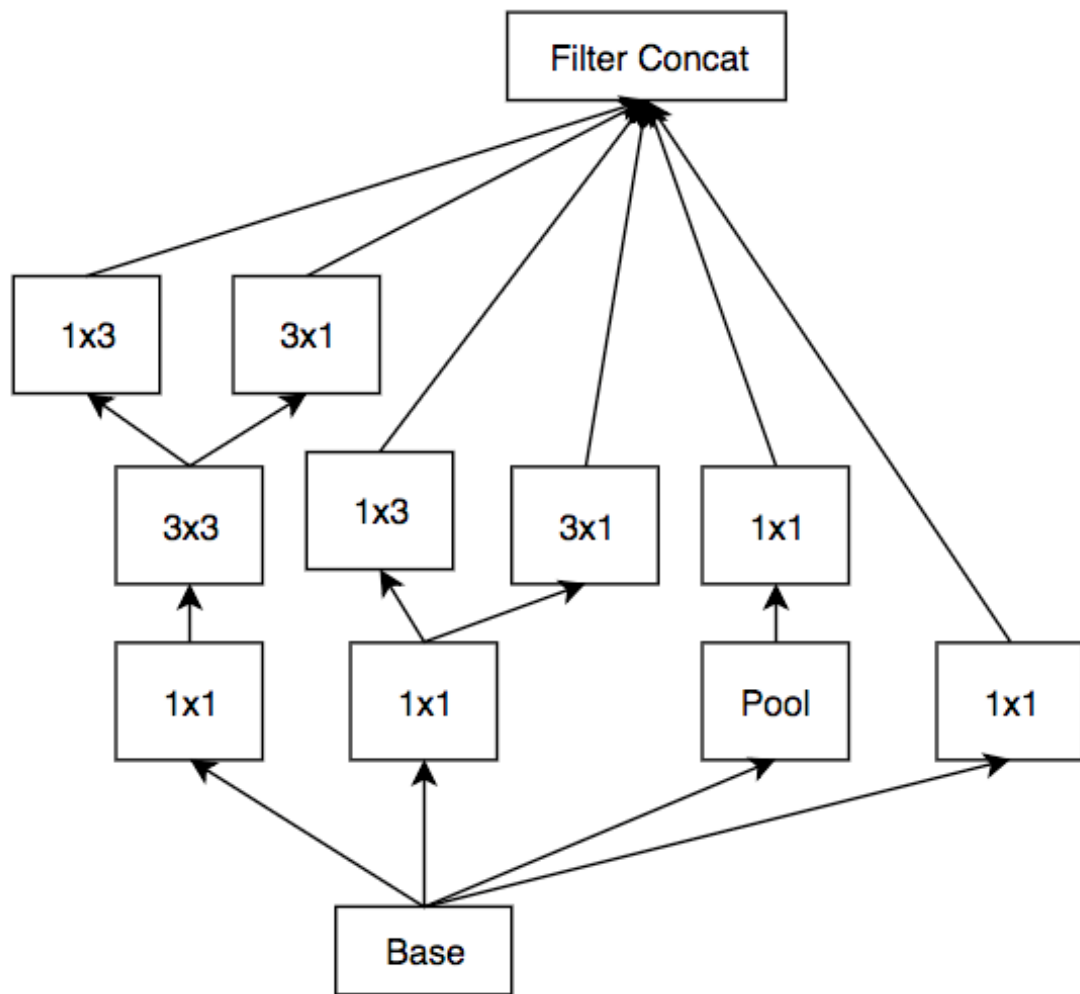


Рисунок 2.13 – Модуль C з використанням асиметричної згортки

Завдяки асиметричній та симетричній факторизаційній згортці досягається зменшення кількості параметрів моделі, що зменшує можливість перенавчання, а отже мережа може отримати глибші дані про зображення.

Ще одні зміни були запропоновані в додаткових класифікаторах. Додаткові класифікатори вже були запропоновані в попередніх архітектурах моделі Inception, таких як GoogleLeNet, але Inception v3 вводить деякі додаткові зміни до них.

Лише один допоміжний класифікатор використовується на вершині останнього шару  $17 \times 17$ , замість використання двох допоміжних класифікаторів (рис. 2.14).

Мета додаткових класифікаторів також відрізняється. У GoogLeNet допоміжні класифікатори використовуються для більш глибокої мережі.

В новій архітектурі моделі Inception v3 допоміжний класифікатор використовується як регуляризатор що додає додаткову інформацію для уникнення перенавчання.

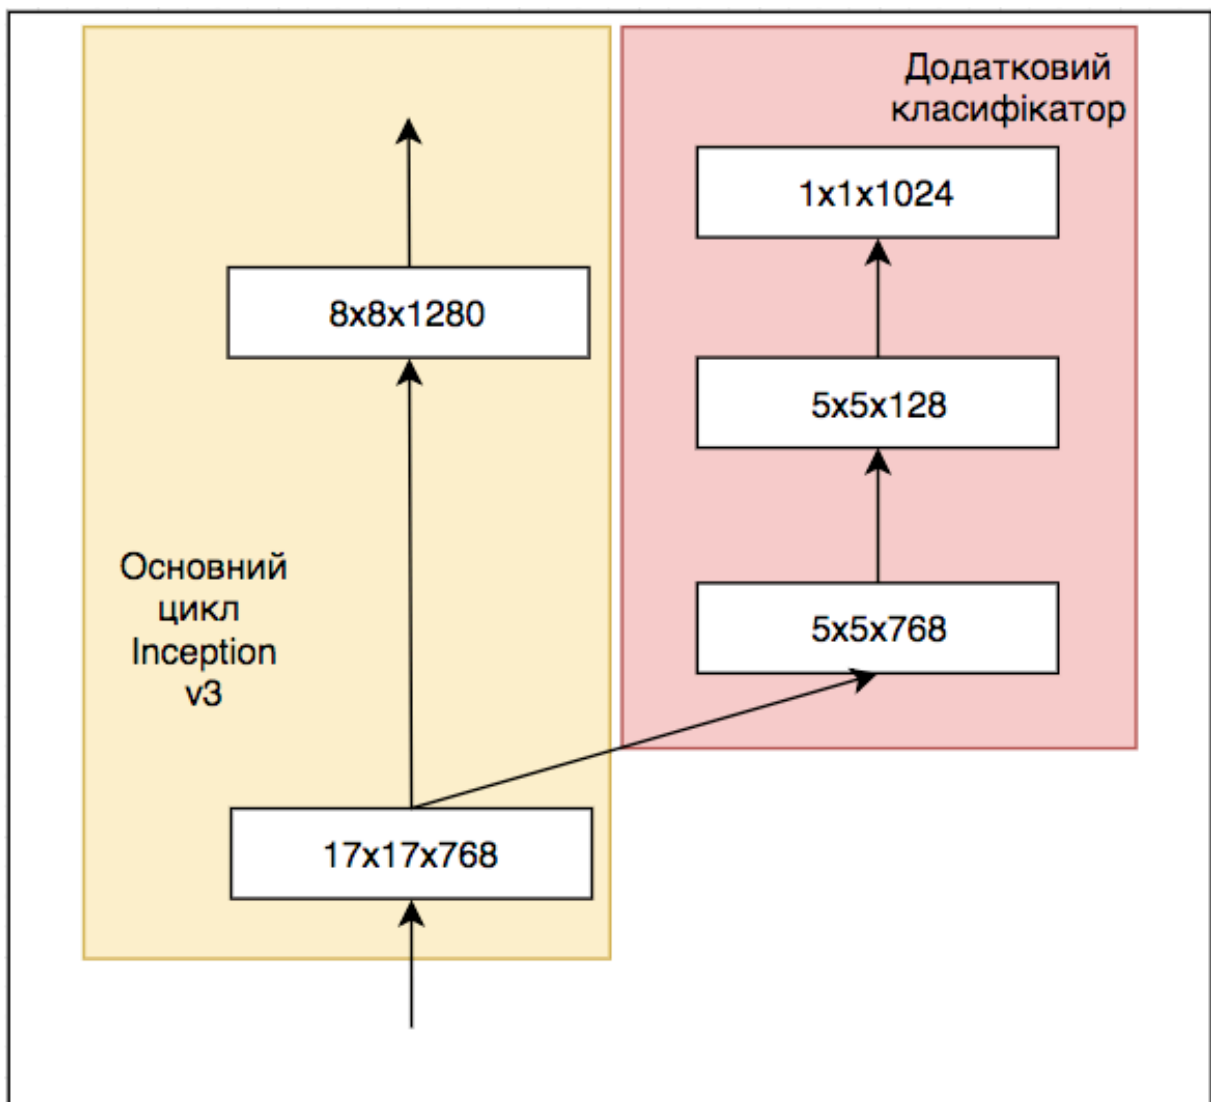


Рисунок 2.14 – Архітектура додаткового класифікатора

Щодо зменшення розміру сітки, у моделях типу AlexNet та VGGNet виконується завдяки шару об'єднання.

Але недоліком є те, що шар об'єднання перед згортковим шаром є занадто неефективним.

Якщо змінити послідовність згорткового шару перед об'єднанням, це виявляється менш затратною операцією (рис. 2.15).




Рисунок 2.15 – Заміна послідовності шарів

Ще одним покращенням яке зменшує обчислення в архітектурі було запропоновано. Якщо змінити послідовність згорткового шару перед об'єднанням, це виявляється менш затратною операцією.

Менш дорога і все ще ефективна мережа досягається завдяки цьому ефективному зменшенню розмірної сітки.

В результаті ми отримуємо покращену модель GoogLeNet, яка отримала назву Inception v3 (рис. 2.16).

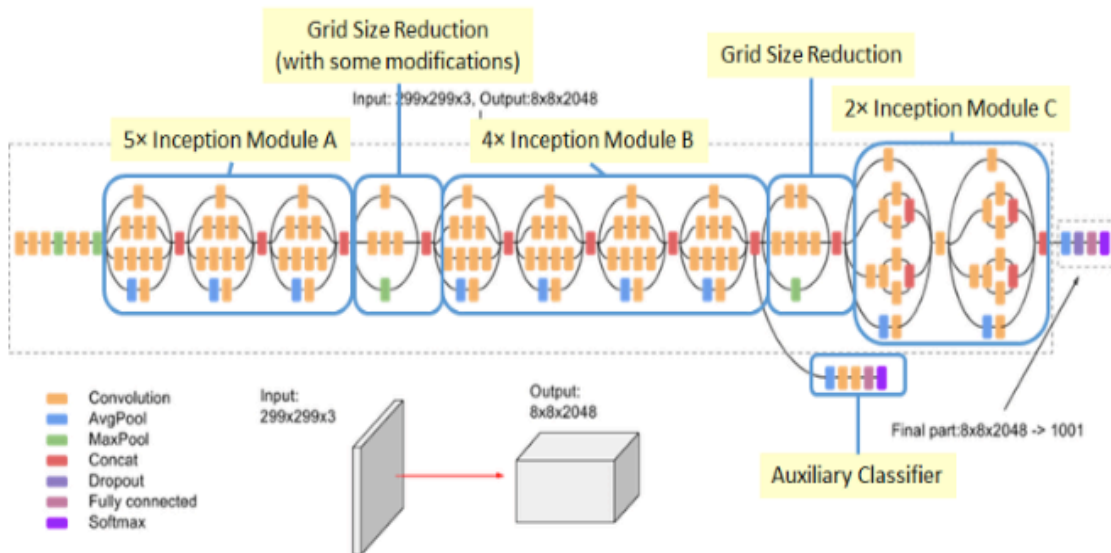


Рисунок 2.16 – Загальна архітектура моделі Inception v3

### 2.3.2 Модель ResNet

Модель ResNet, або яку також називають Residual Network – це нейронна мережа, що будується на конструкціях, так званих пірамідальних клітинах у корі головного мозку [9].

Залишкові шари нейронної мережі за допомогою пропущених з'єднань або коротких скорочень, мають можливість пропускати декілька послідовних шарів.

Коли в архітектурі нейронних мереж починають збільшувати глибину, виникає проблема деградації даних, хоч і точнісінько на початку збільшується, але далі вона починає зменшуватись.

Для прикладу порівняємо звичайні неглибокі нейронні мережі та додамо до них декілька додаткових шарів які виконуватимуть функцію ідентифікації, тобто вхід в мережний шар буде дорівнювати виходу (рис. 2.17).

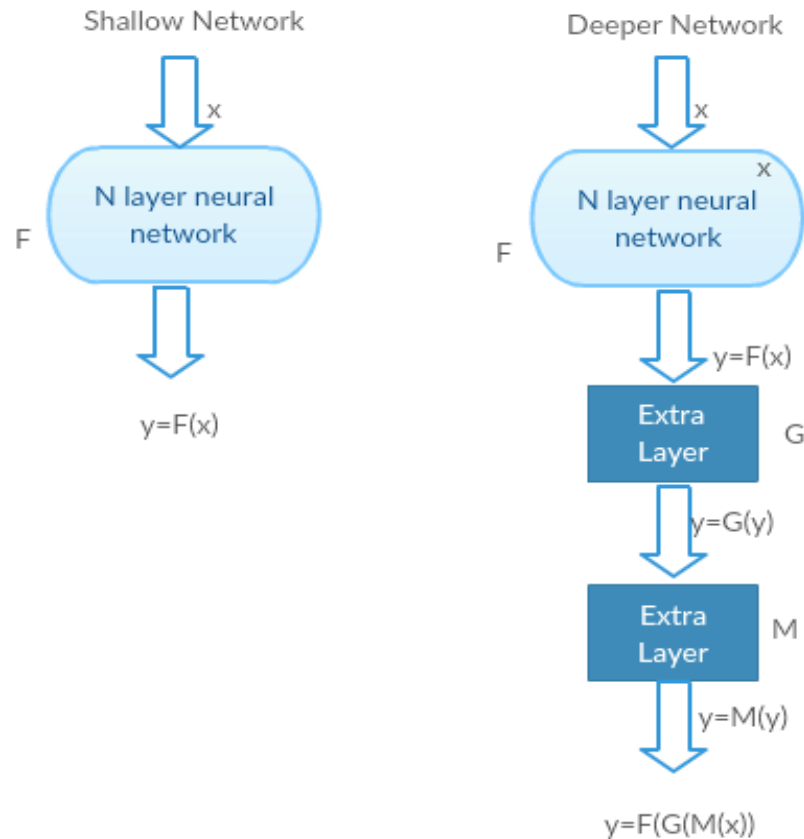


Рисунок 2.17 – Неглибокі нейронні мережі з додатковими шарами

У таких неглибоких мережах додаткові шари  $G$  та  $M$  будуть добре апроксимуватись, ніж шар  $F$ , що значно збільшує точність мережі. У найгіршому випадку неглибока мережа, так і більш глибокий її варіант повинні мати таку ж точність.

В наведеному прикладі, архітектура з глибокою мережею, повинна забезпечувати кращу точність, ніж неглибока модель, оскільки додаткові шари змешують похибку.

Але результати досліджень на практиці показують, що глибші моделі не дають хороших показників, оскільки використання глибших мереж знижує продуктивність моделі та її справжню апроксимацію точності. Ці проблеми намагаються вирішити за допомогою глибокої залишкової архітектури нейронної мережі.

Замість того, щоб вивчати пряме відображення  $x \rightarrow y$  з функцією  $N(x)$ , де  $N(x)$  представляють декілька нелінійних шарів, краще визначити

залишкову функцію з використанням  $F(x) = H(x) - x$ , яку можна перерахувати до  $H(x) = F(x) + x$ , де  $F(x)$  і  $x$  представляють складені нелінійні шари та функцію ідентичності відповідно.

Тобто для такої ситуації простим буде рішення, як  $F(x) = 0$ , але не  $F(x) = x$ , використовуючи стек нелінійних згорток як функцію. Отже, функція  $F(x)$  – це те, що називають залишковою функцією (рис. 2.18).

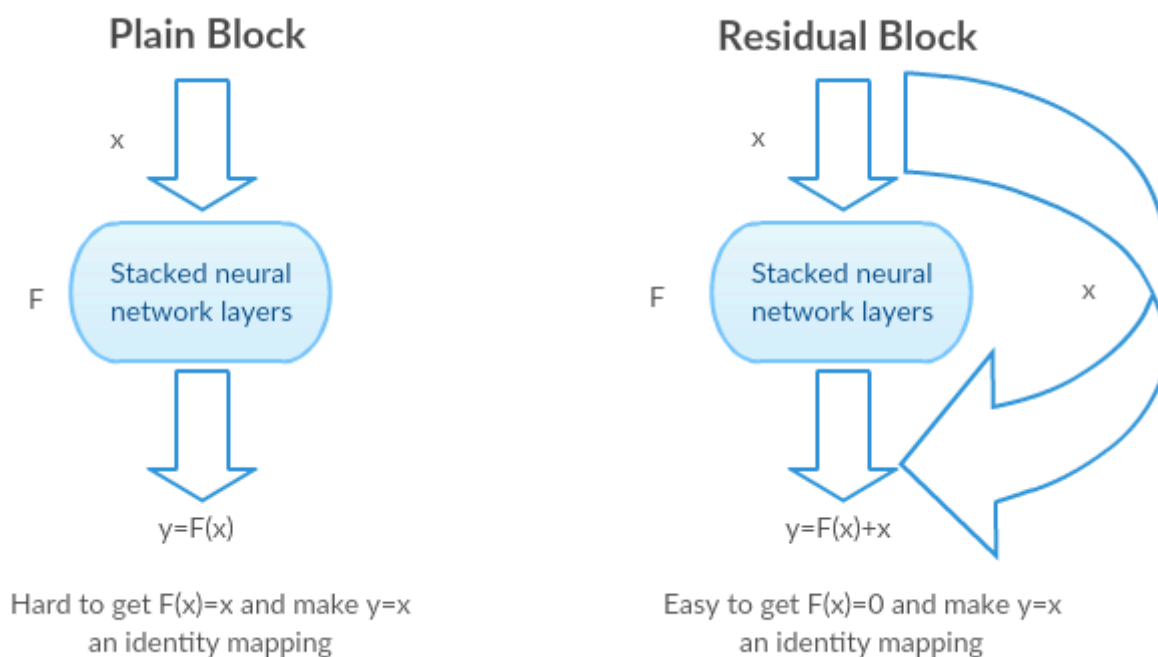


Рисунок 2.18 – Схематичне зображення залишкової функції

Для прикладу, взявши звичайну архітектуру VGGNet з 18 шарами і її глибший варіант з 34 шарами та добавивши залишкові зв'язки, ми отримаємо архітектуру ResNet.

Маючи таку архітектуру моделі, можна використовувати напряду в залишковому блоку значення  $x$ . Для ситуацій, коли розмірність змінюється, ми все ще можемо використати значення  $x$ , як тотожне відображення, лише додавши до нього додатков нульові записи збільшеними розміром [10].

Перевіряючи результати моделі на підготовленому наборі даних ImageNet отримано наступні результати.

Таблиця 3 – Порівняння похибки розпізнавання

кількість шарів / модель	Звичайна VGGNet	ResNet
18 шарів	27.94	27.88
34 шари	28.54	25.03

Представлені архітектури моделей штучних нейронних мереж широко використовуються в задачах розпізнавання та кластеризації зображення.

#### 2.4 Граф доріг

Граф доріг - це цифрова векторна карта, що складається з топологічно пов'язаних дуг і вузлів, розташування і властивості яких із заданою точністю і повнотою передають маршрути і організацію руху наземного транспорту.

Граф доріг створюється згідно з вимогами до навігаційних карт, що включає опис класифікаторів, правил цифрового опису, форматів даних, редакційно-технічні вказівки.

Елементи графа доріг призначені для використання в задачах з автоматизованого створення маршрутів між будь-якими заданими точками на графі.

Граф доріг створюється по виділеним об'єктам дорожньої мережі і представляє собою призначену для користувача карту з дугами і вузлами. На етапі побудови в семантичні характеристики дуг і вузлів записується інформація про зв'язок мережі та атрибути для вирішення пошукових задач. Дуги можна створювати двох видів: з двостороннім рухом та рухом лише в односторонньому порядку.

Засоби редагування графа доріг призначені для уточнення графа в місцях багаторівневих розв'язок і формування заборон поворотів.

Користувач має можливість вручну видалити, додати вузли мережі, замінити дугу з двостороннім рухом на дугу з одностороннім рухом, провести розпаралелювання доріг, створити дуги і розвороти, сформувати на перехрестях заборони поворотів.

Пошук маршруту між точками (населеними пунктами) здійснюється з урахуванням будь-яких характеристик записаних в дуги мережі (тип доріг, швидкість руху, кількість проїзних частин).

Найкоротший маршрут можна знайти або по мінімальній довжині шляху або за мінімальним часом проходження маршруту. При знаходженні мінімального шляху є можливість виключення деяких дуг, наприклад аварійних ділянок, з пошуку. Результати пошуку відображаються на карті у вигляді об'єкта - маршруту.

Граф доріг і дорожніх споруд чи магістралей створюється у вигляді окремої користувальницької карти без поділу на номенклатурні аркуші. Об'єкти, що описують граф доріг, складають окремий шар в класифікаторі цифрових навігаційних планів міст. Граф доріг містить два основних типи об'єктів: дуги і вузли.

Дуги графа будуються, як правило, по осьовим лініям вулиць, доріг і дорожніх споруд, із забезпеченням топології в точках примикання. Односторонні дуги повинні мати напрямок цифрування, що збігається з напрямком руху по даній дузі. Дуги з двостороннім рухом можуть мати довільний напрямок цифрування.

Вузли можуть послідовно з'єднувати дві дуги, що мають різні характеристики, або з'єднувати кілька дуг в місцях перехресть, розвилок і т.п. Якщо дороги фізично проходять над однією ділянкою місцевості на різних рівнях (тунель, естакада тощо), то в точці перетину доріг на карті графа вузол повинен бути відсутнім.

За допомогою набору односторонніх і двосторонніх дуг і вузлів можна однозначно описати різні види перехресть, однорівневих і багаторівневих розв'язок. Якщо на перехресті доріг необхідно показати

заборону повороту, то в цьому місці дороги можуть бути показані паралельними односторонніми дугами, які мають вузли тільки з перетинаючими дугами, на яких дозволено перестроювання транспорту (рис. 2.19).




Рисунок 2.19 – Граф доріг для складного перехрестя

## 2.5 Заданя векторного відображення на картах

Однією з картографічних проблем є відображення векторної геометрії на проєкціях Землі. Почнемо перш за все з найбільш розповсюдженої проєкції, так званої географічної проєкції, або її ще називають геометрія широт.

Строго кажучи, вона навіть не зовсім є проєкцією, тому що виходить шляхом інтерпретації полярних кутових координат, як лінійних прямокутних, без всяких обчислень. Цю проєкцію використовують, тому що вона здатна відобразити всю поверхню Землі цілком і тому, що вона найпростіша математично, а дані дуже часто поширюються не спроектовані, тобто саме в географічних координатах (градусах широти і довготи).

В результаті проєкції виходить прямокутник, де точки полюсів звернені в лінії (верхню і нижню межі). Чим далі від екватора, тим сильніше будь-який об'єкт на карті виявляється сплюснутим по вертикалі і розтягнутий по горизонталі. Ця проєкція підходить для відображення глобальних наборів даних, але полярні території (Канада, Норвегія, Швеція, Фінляндія, Гренландія, Антарктида, Ісландія) виявляються спотворені (рис. 2.20).




Рисунок 2.20 – Географічна проєкція Землі

Проєкції, які дозволяють уникнути цього, існують, і одну з таких проєкцій використано для задання графу доріг в роботі. Єдина причина використовувати географічну проєкцію - її гранична простота програмної реалізації. Потрібно просто відобразити систему координат від  $-180^\circ$  до  $180^\circ$  по  $X$  і від  $-90^\circ$  до  $90^\circ$  по  $Y$  на площину, вважаючи кутові одиниці лінійними.

Але через спотворення відображення реальних розмірів, загальною прийнятою проєкцією для візуалізації даних, покриваючих весь світ, є проєкція Меркатора.

Її популярність продиктована не тільки її простотою, але і тим що її

варіанти являються стандартом де-факто для глобальних картографічних сервісів, таких як Google Maps, Leaflet, OpenStreetMap. В варіанті OpenStreetMap вона називається Web Mercator та має код EPSG:900913. Принцип її побудови не сильно складніший за географічну проекцію.

Проекція Меркатора - це проекція на циліндр, чия вісь збігається з географічною віссю Землі, проектування відбувається лініями, що виходять з центру планети, від чого помилка розтягування приполярних областей по горизонталі виявляється скомпенсована пропорційним розтягуванням по вертикалі.

Проблема з цим тільки в тому, що карта вийде занадто великою по вертикалі, якщо спробувати відобразити і північ Гренландії.

Тому зазвичай відкидають 16° полярних областей (в рівній пропорції або більше з півдня).

В системі розпізнавання для зберігання векторного результату використовується саме ця проекція, оскільки вона дозволяє відобразити дані без спотворень, а також є стандартизованою для багатьох сервісів відображення векторних даних різних форматів GeoJSON, KML, SHP.

GeoJSON – відкритий формат, призначений для зберігання географічних структур даних, заснований на JSON (рис. 2.21). Формат може зберігати приміркові типи для опису географічних об'єктів, таких як: точки (адреси та розташування), лінії (вулиці, шосе, межі), полігони (країни, штани, ділянки землі). Так само можуть зберігатися так звані мультитипи, які представляють собою об'єднання декількох примірних типів.

Формат GeoJSON відрізняється від інших стандартів ГІС тим, що він був написаний і підтримується не будь-якою організацією по стандартизації, а за допомогою робочої групи розробників.

```

{
  "type": "FeatureCollection",
  "crs": {
    "type": "name",
    "properties": {"name": "urn:ogc:def:crs:OGC:1.3:CRS84" }
  },
  "features": [
    {
      "type": "Feature",
      "properties": {"road_id": 3108},
      "geometry":
      {
        "type": "LineString",
        "coordinates": [ [2.209757491211178, 49.0354209], [2.20931561078,
49.035864115419997], [2.20922639996, 49.035959313542605]]
      }
    }
  ]
}

```

Рисунок 2.21 – Приклад GeoJSON формату

Shapefile (SHP) – векторний формат для зберігання об'єктів, що описуються геометрією і супутніми атрибутами. У форматі відсутня можливість зберігання топологічної інформації.

Формат був представлений для ArcView GIS версії 2 на початку 1990-х років. На сьогоднішній день існує велика кількість програм для роботи з shape-файлами. Через свою поширеність, формат став де-факто стандартом для обміну даними між геоінформаційними системами.

KML – це XML-позначення для вираження географічної анотації та візуалізації в Інтернеті на двовимірних та тривімирних мапах Землі. KML був розроблений для використання в Google Earth, який спочатку був названий Keyhole Earth Viewer.

KML став міжнародним стандартом відкритого геопросторового консорціуму у 2008 році. KML підтримує декілька видів об'єктів, таких як маркери, зображення, полігони, 3д моделі та текстовий опис (рис. 2.22).

```
<?xml version="1.0" encoding="UTF-8"?>
<kml xmlns="http://www.opengis.net/kml/2.2">
<Document>
<Placemark>
  <name>New York City</name>
  <description>New York City</description>
  <Point>
    <coordinates>-74.006393,40.714172,0</coordinates>
  </Point>
</Placemark>
</Document>
</kml>
```

Рисунок 2.22 – Приклад KML формату

Отже порівнюючи представлені архітектури штучних нейронних мереж для розпізнавання та кластеризації зображень за основу взята архітектурна модель Inception v3 додаючи до неї декілька шарів з моделі ResNet аби покращити точність результатів та збільшити апроксимацію точності розпізнавання. Також в якості декодерів було обрано добре відоме рішення, представлене раніше в архітектурі LinkNet, що дозволило декодувати зображення у маску доріг.

Для збереження результату графу доріг було взято GeoJSON формат оскільки він є універсальним форматом який використовується у геоінформаційних системах та не складний у формуванні.

## Висновки до розділу 2

1. Проведено аналітичний огляд методів розпізнавання зображень на основі штучних нейронних мереж,
2. Проаналізовано принципи роботи та загальну архітектуру моделей штучних нейронних мереж для розпізнавання зображень.
3. На основі порівняння моделей розроблено архітектуру моделі розпізнавання магістралей на супутникових зображеннях на основі моделі Inception v3 та з доданням до неї додаткових шарів з архітектри

ResNet та застосування архітектури LinkNet в якості декодерів.

4. Наведено приклади представлення географічних векторних даних в сучасних геоінформаційних системах.
5. Вибрано формат GeoJSON в якості результуючого формату представлення графу доріг.

## РОЗДІЛ 3. ОПИС РОЗРОБЛЕНОЇ СИСТЕМИ

Для розробки системи потрібно створити модуль, який буде обробляти супутникові знімки високої роздільної здатності, використовуючи основну архітектурну модель штучної нейронної мережі та створювати маску доріг. Окремим модулем потрібно розробити модуль перетворення маски доріг та збереження у вигляді графу доріг, який дозволить відобразити його в геоінформаційних системах.

### 3.1 Модуль розпізнавання супутникового зображення

Система ідентифікації магістралей на супутникових зображеннях являє собою певний модуль який отримує на вхід зображення, а результатом розпізнавання є побудова маски доріг, після чого маска перетворюється у векторне відображення графу ідентифікованих доріг.

Розробку системи проведено на мові програмування Python використовуючи бібліотеку PyTorch.

Мова програмування Python являється досить популярною мовою для програмування різного роду автоматизаційних програм. Ця мова набула своєї популярності завдяки простоті і великому об'єму додаткових бібліотек для реалізації будь-яких задач. В сучасному світі, мова Python стала однією з найпопулярніших в сферах аналізу даних та штучних нейронних мереж. Саме тому була обрана для реалізації задачі по розпізнаванню магістралей на супутникових зображеннях.

Бібліотека PyTorch є однією з відомих бібліотек в області аналізу даних та штучних нейронних мереж. Ця бібліотека дозволяє зручно створювати власні архітектури нейронних мереж, оскільки вона має можливість відразу додавати готову реалізацію шарів нейронних мереж, вибираючи на свій розсуд тип шару і кількість його параметрів.

Для створення такої системи було зібрано навчальний та валідаційний набір даних.

Перш за все, система отримує на вхід супутникове зображення високої роздільної здатності (рис. 3.1).



Рисунок 3.1 – Зображення місцевості

Експериментальним шляхом було отримано, що роздільна здатність для якісної обробки зображення має бути не менше 1м на піксель, оскільки загальна ширина доріг не менше 2.7 м.

Першим етапом створення системи було створення моделі штучної нейронної мережі. Для цього було створено програму для навчання моделі та валідації її розпізнавання на основі порівняння результату розпізнавання

з зображеннями масок доріг.

Процес навчання завжди можна було прервати та продовжити з місця зупинки. Створенна нейронна мережа зберігалась для подальшого використання.

При цьому кожна з ітерацій навчання повертає результат навчання у вигляді кількості оброблених фото з навчального набору даних та оцінку навчання (рис. 3.2).

```
[users-Air:RoadDetection Kryvonis$ python main.py
Train Epoch: 1 [0/10000 (0%)]          Loss: 49.6105950915483
Train Epoch: 1 [100/10000 (1%)]       Loss: 49.571074710993656
Train Epoch: 1 [200/10000 (2%)]       Loss: 49.06267997054115
Train Epoch: 1 [300/10000 (3%)]       Loss: 49.74955351099946
Train Epoch: 1 [400/10000 (4%)]       Loss: 49.99766866015014
Train Epoch: 1 [500/10000 (5%)]       Loss: 49.79984799775944
Train Epoch: 1 [600/10000 (6%)]       Loss: 49.91028017277515
Train Epoch: 1 [700/10000 (7%)]       Loss: 49.6835873675432
Train Epoch: 1 [800/10000 (8%)]       Loss: 49.890640490730135
Train Epoch: 1 [900/10000 (9%)]       Loss: 49.69913688916539
Train Epoch: 1 [1000/10000 (10%)]     Loss: 49.28294049031461
Train Epoch: 1 [1100/10000 (11%)]    Loss: 49.31498259400766
Train Epoch: 1 [1200/10000 (12%)]    Loss: 49.714852313132404
Train Epoch: 1 [1300/10000 (13%)]    Loss: 49.769754757495065
Train Epoch: 1 [1400/10000 (14%)]    Loss: 49.530464662580734
Train Epoch: 1 [1500/10000 (15%)]    Loss: 49.253713345224156
Train Epoch: 1 [1600/10000 (16%)]    Loss: 49.140375256756315
Train Epoch: 1 [1700/10000 (17%)]    Loss: 49.588107667028154
Train Epoch: 1 [1800/10000 (18%)]    Loss: 49.18727008659967
Train Epoch: 1 [1900/10000 (19%)]    Loss: 49.36355646239006
Train Epoch: 1 [2000/10000 (20%)]    Loss: 49.48665914103395
Train Epoch: 1 [2100/10000 (21%)]    Loss: 49.93158675115996
Train Epoch: 1 [2200/10000 (22%)]    Loss: 49.049525647807656
```

Рисунок 3.2 – Початок першої епохи навчання

Етапи навчання були розбиті на ітерації та епохи з партією в 100 навчальних зображень. Ітерація – це прохід по архітектурі нейронної мережі в одну сторону та назад використовуючи пакет зображень. В той же час епоха – це прохід алгоритму навчання через усі навчальні зображення.

Як видно з результатів початку першої епохи навчання, функція перевірки похибки показує результат в середньому 49%.

Цей результат є лише результатом початку навчання і являється очікуваним, оскільки нейронна мережа ще не навчена для розпізнавання, тому слід продовжувати навчання.

При цьому слід уважно спостерігати за оцінкою похибки розпізнавання нейронної мережі, оскільки вона хоч і може збільшуватись на певних ітераціях, але в загальному функція оцінки похибки повинна поступово зменшуватись (рис. 3.3).

Train Epoch: 1 [8300/10000 (83%)]	Loss: 44.90095653344659
Train Epoch: 1 [8400/10000 (84%)]	Loss: 44.168631454010296
Train Epoch: 1 [8500/10000 (85%)]	Loss: 44.71155094743648
Train Epoch: 1 [8600/10000 (86%)]	Loss: 43.90083844238333
Train Epoch: 1 [8700/10000 (87%)]	Loss: 44.00953522154296
Train Epoch: 1 [8800/10000 (88%)]	Loss: 43.187132066701565
Train Epoch: 1 [8900/10000 (89%)]	Loss: 44.07480322662995
Train Epoch: 1 [9000/10000 (90%)]	Loss: 43.671887935021466
Train Epoch: 1 [9100/10000 (91%)]	Loss: 43.70205466179833
Train Epoch: 1 [9200/10000 (92%)]	Loss: 44.8278007501548
Train Epoch: 1 [9300/10000 (93%)]	Loss: 44.60439635202647
Train Epoch: 1 [9400/10000 (94%)]	Loss: 44.69367869306435
Train Epoch: 1 [9500/10000 (95%)]	Loss: 44.56348818959401
Train Epoch: 1 [9600/10000 (96%)]	Loss: 44.12559956775724
Train Epoch: 1 [9700/10000 (97%)]	Loss: 44.414618953009104
Train Epoch: 1 [9800/10000 (98%)]	Loss: 44.364738355874074
Train Epoch: 1 [9900/10000 (99%)]	Loss: 43.64041083217803
Train Epoch: 1 [10000/10000 (100%)]	Loss: 44.03155793693918

Рисунок 3.3 – Кінець першої епохи навчання

Якщо функція оцінювання похибки розпізнавання з епохами не спадає, або взагалі почала зростати – це може бути признаком того що модель починає перенавчатись.

Процес навчання можна було прервати, оскільки система зберігала модель нейронної мережі, тобто всі значення параметрів, на кожній з епох навчання.

В результаті навчена модель зберігалась у форматі pickle для подальшої можливості завантаження її до системи та використання для розпізнавання.

Результатом розпізнавання зображення було зображення подібне до

зображення маски доріг, лише з певним шумом, тобто дрібними білими плямами (рис. 3.4).



Рисунок 3.3 – Результат розпізнавання місцевості

### 3.2 Модуль побудови графу доріг

Отримане зображення маски доріг є входним для обробки в модулі побудови графу доріг.

Для побудови векторного представлення графу доріг, створено окремий блок системи який на основі даних отриманих з масок доріг

поєднував магістралі та відкидав хибно знайдені шляхи.

В результаті роботи цього блоку розпізнавання формується файл з геолокаційними даними, які далі можливо було використовувати в різних геоінформаційних системах. Наприклад файли такого формату можливо відобразити в системах Kepler та EOS Vision.

Дороги у супутникових зображеннях високої роздільної здатності в основному відповідають областям з локально постійною спектральною сигналізацією.

Яскраві або темні лінії можна видобути з точністю до субпікселів, виходячи з лише декількох параметрів, наприклад, максимальної ширини. Лінії витягуються після кластеризації у супутниковому зображенні високої роздільної здатності.

Зображення маски доріг є корисним як канал для видобутку ліній, завдяки добре відомій поведінці доріг у ній та отриманої простої та надійного налаштування параметрів вилучення: дороги в зображеннях маски завжди виглядають як білі яскраві лінії з темним оточенням.

Для побудови графу доріг було перш за все усунено шум з утвореного результату розпізнавання. За шум на зображенні взято об'єкти, площа яких менше за 300 пікселів.

Після цього зображення оброблялось алгоритмом *skeletonization*. *Skeletonization* – це процес обробки зображення, при якому контури зводяться покроково до тонкої лінії шириною в один піксель.

В результаті зображення маски перетворюється в зображення контурів, тобто тонких ліній доріг.

Далі на результаті обробки маски, з новоутвореним зображенням ліній доріг, застосовується трансформація зображення у граф доріг (рис. 3.4).

В результаті обробки зображення програмою на виході буде сформовано файл формату GeoJSON в якому записано інформацію векторного представлення графу доріг.

Оскільки у вхідному зображенні записана геолокаційна інформація, перетворення в граф дозволяє передати координати місцевості для відображення графу в геоінформаційних системах.




Рисунок 3.4 – Результат побудови графу доріг

Отже розроблена система дає змогу розпізнавати магістралі та будувати маски доріг на супутникових зображеннях високої роздільної здатності використовуючи нейронні мережі.

Створений граф доріг на основі розпізнаних магістралей на супутникових зображень дозволяє використовувати граф в сучасних геоінформаційних системах.

## Висновки до розділу 3

1. Розроблений спосіб та система розпізнавання магістралей на супутникових зображеннях високої роздільної здатності.
2. Проаналізовано принципи роботи та загальну архітектуру системи розпізнавання магістралей на супутникових зображеннях використовуючи штучні нейронні мережі.
3. Розроблений модуль побудови графу доріг з використанням алгоритму skeletonization та зображення маски доріг, на основі вхідного супутникового зображення та зображення маски доріг, створено граф доріг для відображення в геоінформаційних системах.

## РОЗДІЛ 4. АНАЛІЗ РОЗРОБЛЕНОЇ СИСТЕМИ РОЗПІЗНАВАННЯ МАГІСТРАЛЕЙ

Розроблена система розпізнавання магістралей на основі супутникових зображень дозволяє отримати граф доріг для відображення в геоінформаційних системах. Але для повноти її розуміння потрібно провести аналіз якості розпізнавання та інших параметрів, аби оцінити її сповна.

### 4.1 Оцінка точності розпізнавання автомагістралей

Для оцінювання системи варто перш за все оцінити якість розпізнавання магістралей та побудови маски доріг. Для оцінки якості розпізнавання було використано підхід Intersection over Union (IoU).

Intersection over Union або перетин над поєднанням це один із методів оцінювання якості розпізнавання об'єкту на зображенні. Оцінка IoU – це стандартний показник продуктивності розпізнавання для задач категорії сегментації об'єктів. Враховуючи набір зображень, міра IoU дає подібність між прогнозованою областю та регіоном істини для наявного об'єкта в наборі зображень і визначається наступним рівнянням.

$$IoU = \frac{TP}{FP + TP + FN} .$$

Де значення True Positive (TP) дорівнює кількості правильно отриманих пікселів значенням 1 на результуючому зображенні в порівнянні з тестовим.

False Positive (FP) – кількість хибно отриманих пікселів з значенням 1, тобто білих областей на розпізнаному зображенні маски, хоча на тестовому зображенні піксель в значенні 0.

Значення False Negative (FN) – це кількість пікселів які не були розпізнані вірно, тобто на зображенні маски що згенерувала штучна нейронна мережа значення дорівнює 0, хоча на тестовому зображенні значення дорівнює 1.

Перетин над об'єднанням є базовим методом оцінки сегментації зображення, що дозволяє отримати кількісні результати якості розпізнавання магістралей на супутникових зображень. Також оцінка IoU являється характеристикою для навчання мережі.

Навчання та тестування мережі проводились на процесорі 1.4 GHz Intel Core i5 та з графічним процесором Intel HD Graphics 5000. Одним із параметрів навчання є learning rate (lr), який задається перед навчанням моделі для градієнтного спуску. Якщо обрати значення lr великим, існує можливість недовчити мережу, але чим менше значення lr тим довше мережа навчається.

Навчання нейронної мережі проходило в декілька ітерацій. Першим етапом навчання було 20 епох з lr в  $1 \cdot 10^{-4}$ . Далі значення lr зменшувалось аби отримати точніше наближення моделі.

За результатами навчання штучної нейронної мережі було отримано наступні результати

Таблиця 4 – Результати навчання нейронної мережі

Параметри навчання	lr	IoU
Кількість епох		
20 епох	$1 \cdot 10^{-4}$	64.33
5 епох	$2 \cdot 10^{-5}$	65.94
5 епох	$5 \cdot 10^{-6}$	68.89

Результати розпізнавання показують що система здатна знаходити магістралі та дороги використовуючи супутникові знімки високої роздільної здатності.

#### 4.2 Оцінка часу на розпізнавання автомагістралей

Основна частина часу для підготовки системи до робочого стану займав процес навчання нейронної мережі. Ці а також і час на розпізнавання одного зображення готовою моделю проводились використовуючи комп'ютер з процесором 1.4 GHz Intel Core i5 та з графічним процесором Intel HD Graphics 5000.

Для заміру часу для навчання нейронної мережі використовувались стандартні можливості мови програмування Python.

Таблиця 5 – Часові затрати на навчання мережі

Кількість епох	Параметри навчання	$lr$	$t$ (год)
20 епох		$1 \cdot 10^{-4}$	23.1
5 епох		$2 \cdot 10^{-5}$	25.6
5 епох		$5 \cdot 10^{-6}$	27.0


Час для розпізнавання одного зображення в середньому займав однаково в незалежності від натренованості мережі. Оскільки часові показники розпізнавання не пов'язані з навчанням штучної нейронної мережі.

Час для розпізнавання одного зображення в 1024x1024 пікселі середньому займав  $\approx 30$  сек.

### 4.3 Оцінка точності побудови графу доріг

Наше зосередження на дорожніх мережах, природно, змушує нас розглядати теорію графів як засіб оцінки точності побудови графу доріг. Хоча існує багато пропозицій щодо подібності графів, вони, як правило, зосереджуються на логічній топології (зв'язок між вузлами) графа, тоді як нам важлива як логічна топологія, так і фізична топологія доріг. Оскільки в першу чергу гіс-спеціалісти зацікавлені в маршрутизації, ми будемо використовувати графічну метрику на основі алгоритму найкоротшого шляху Дейкстра. Підсумовуючи відмінності в оптимальних шляхах між наземними істинами доріг та запропонованим графом доріг.

Щоб виміряти різницю між графом істини та графом створеним системою, використовується метрика average path length similarity (APLS), яка об'єднує різницю в оптимальних довжинах шляху між вузлами в графі оригіналу та у графі створеним системою. Пропущені шляхи в Метричні шкали APLS від 0 (погано) до 1 (ідеально) (рис. 4.1, рис. 4.2).



Тестовий граф

Граф створений системою

Рисунок 4.1 – Тестовий та результуючий графи доріг




Рисунок 4.2 – Різниця маршрутів на графах

Метрика APLS розроблена таким чином, щоб заохотити знаходження правильного розташування вузла та можливість його підключення, і тому має показувати кращу оцінку ніж лише IoU (рис. 4.3).




Рисунок 4.3 – Різниця оцінок для графу та маски доріг

Звичайно оцінка розпізнавання графу залежить від якості розпізнавання супутниковго зображення високої роздільної здатності. Оцінка якості розпізнавання проведена для кожного етапу навчання на тестовому наборі зображень представлена в таблиці 6.

Таблиця 6 – Оцінка розпізнавання графу доріг

Кількість епох \ Параметри навчання	$lr$	ССДШ
20 епох	$1 \cdot 10^{-4}$	54.32
5 епох	$2 \cdot 10^{-5}$	56.90
5 епох	$5 \cdot 10^{-6}$	59.04

## Висновки до розділу 4

1. Проаналізовано метод оцінки результатів роботи системи розпізнавання магістралей на супутникових зображеннях використовуючи штучні нейронні мережі.
2. Наведені оцінки точності розпізнавання магістралей на супутникових зображеннях використовуючи метод Intersection over Union.
3. Наведена оцінка часових затрат на навчання штучної нейронної мережі для розпізнавання магістралей на супутникових зображеннях високої роздільної здатності.
4. Проаналізовано метод оцінки результатів побудови графу доріг використовуючи розроблену систему розпізнавання магістралей на супутникових зображеннях.
5. Проаналізовано можливості застосування розробленої системи розпізнавання магістралей на супутникових зображеннях використовуючи штучні нейронні мережі.

## ВИСНОВКИ

1. Проведено огляд та проаналізовано методи отримання супутникових зображень, існуючі підходи до розпізнавання зображень використовуючи сучасні системи ідентифікації на базі штучних нейронних мереж. Проведено порівняння штучних нейронних мереж та методів для розпізнавання та сегментації зображень. Проаналізовано принципи роботи та загальну архітектуру моделей штучних нейронних мереж для розпізнавання зображень.
2. На основі порівняння моделей розроблено архітектуру моделі розпізнавання магістралей на супутникових зображеннях на основі моделі Inception v3 та з доданням до неї додаткових шарів з архітектури ResNet та застосування архітектури LinkNet в якості декодерів.
3. Розроблено спосіб та систему розпізнавання магістралей на супутникових зображеннях високої роздільної здатності. Проаналізовано принципи роботи та загальну архітектуру системи розпізнавання магістралей на супутникових зображеннях використовуючи штучні нейронні мережі.
4. Розроблено модуль системи для побудови графу доріг на основі вхідного супутникового зображення та зображення маски доріг для відображення в геоінформаційних системах.
5. Наведені оцінки точності та часових затрат на навчання та розпізнавання магістралей на супутникових зображеннях використовуючи розроблену систему.

## СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. Железняк О.О. Космічна фотограмметрія / Железняк О.О., Чубко Л.С. – Київ: Міністерство освіти і науки, молоді та спорту України, 2012. – 216 с.
2. Бурштинська Х. В. Аерокосмічні знімальні системи / Бурштинська Х.В., Станкевич С.А. – Львів: Видавництво Львівської політехніки, 2010. – 292 с.
3. Підготовлений набір даних Linknet // Режим доступу: <https://codeac29.github.io/projects/linknet/index.html>
4. Підготовлений набір даних CamVid // Режим доступу: <http://mi.eng.cam.ac.uk/research/projects/VideoRec/CamVid/>
5. Підготовлений набір даних CityScapes // Режим доступу: <https://www.cityscapes-dataset.com/>
6. Atiqur Rahman. Optimizing Intersection-Over-Union in Deep Neural Networks for Image Segmentation / Atiqur Rahman, Wang Y. // Режим доступу: <https://www.cs.umanitoba.ca/~ywang/papers/isvc16.pdf>
7. Christian Szegedy. Rethinking the Inception Architecture for Computer Vision // Режим доступу: [https://www.cv-foundation.org/openaccess/content\\_cvpr\\_2016/papers/Szegedy\\_Rethinking\\_the\\_Inception\\_CVPR\\_2016\\_paper.pdf](https://www.cv-foundation.org/openaccess/content_cvpr_2016/papers/Szegedy_Rethinking_the_Inception_CVPR_2016_paper.pdf)
8. Rayed Bin Wahed. Comparative Analysis between Inception-v3 and Other Learning Systems using Facial Expressions Detection // Режим доступу: [http://dspace.bracu.ac.bd/xmlui/bitstream/handle/10361/6397/12201020%20%26%2016141024\\_CSE.pdf?sequence=1&isAllowed=y](http://dspace.bracu.ac.bd/xmlui/bitstream/handle/10361/6397/12201020%20%26%2016141024_CSE.pdf?sequence=1&isAllowed=y)
9. Kaiming He. Deep Residual Learning for Image Recognition / Xiangyu Zang, Shaoqing Ren, Jian Sun // Режим доступу: [https://www.cv-foundation.org/openaccess/content\\_cvpr\\_2016/papers/He\\_Deep\\_Residual\\_Learning\\_CVPR\\_2016\\_paper.pdf](https://www.cv-foundation.org/openaccess/content_cvpr_2016/papers/He_Deep_Residual_Learning_CVPR_2016_paper.pdf)

10. Simard P.Y. A Best practices for convolutional neural networks applied to visual document analysis / Steinkraus D., J.C. Platt // Режим доступа: <https://ieeexplore.ieee.org/document/1227801>