

**КИЇВСЬКИЙ НАЦІОНАЛЬНИЙ УНІВЕРСИТЕТ  
ІМЕНІ ТАРАСА ШЕВЧЕНКА  
Факультет інформаційних технологій  
Кафедра інтелектуальних технологій**

**ВИПУСКНА КВАЛІФІКАЦІЙНА РОБОТА  
БАКАЛАВРА**

на тему:

**«Програмний модуль відстеження вирубки лісових  
масивів на основі супутникових даних  
методами машинного навчання»**

Галузь знань **12 «Інформаційні технології»**

Спеціальність **122 «Комп'ютерні науки»**

Освітня програма **«Комп'ютерні науки»**

Освітній рівень: **бакалавр**

Виконала:  
студентка 4 курсу групи КН-41  
Синявська Євгенія Романівна

Керівник:  
Сорока Петро Миколайович,  
кандидат фізико-математичних наук, доцент

Випускна кваліфікаційна робота бакалавра допущена до захисту  
рішенням кафедри *інтелектуальних технологій*  
Протокол № 11 від 06.06.2022 р.  
Зав. кафедри \_\_\_\_\_ доц. Іларіонов О.Є.

**Київ–2022**

**КИЇВСЬКИЙ НАЦІОНАЛЬНИЙ УНІВЕРСИТЕТ ІМЕНІ ТАРАСА  
ШЕВЧЕНКА**

Факультет інформаційних технологій  
Кафедра інтелектуальних технологій  
Спеціальність 122 «Комп'ютерні науки»

ЗАТВЕРДЖУЮ  
Завідувач кафедри  
інтелектуальних технологій  
Іларіонов О.Є.

\_\_\_\_\_ 2022 р.  
“ \_\_\_ ” \_\_\_\_\_

**ЗАВДАННЯ  
НА ВИПУСКНУ КВАЛІФІКАЦІЙНУ РОБОТУ СТУДЕНТОВІ**

Синявської Євгенії Романівни  
(прізвище, ім'я, по батькові)

1. Тема проекту (роботи)  
«Програмний модуль відстеження вирубки лісових масивів на основі супутникових даних методами машинного навчання», затверджена протоколом засідання кафедри від « 23 » грудня 2021 р. № 4
2. Термін здачі студентом закінченого проекту (роботи) 29 травня 2022 року
3. Вихідні дані до проекту (роботи)  
Результати класифікації супутникових знімків ділянки Передкарпаття.
4. Зміст розрахунково-пояснювальної записки (перелік питань, що їх належить розробити)
  1. Вступ.
  2. Аналітичний огляд предметної області.
  3. Розробка архітектури класифікації лісових масивів за допомогою методів машинного навчання.
  4. Створення нейронних мереж, опис та результати роботи програми.
  5. Висновки.


Перелік презентаційного матеріалу (з точним зазначенням обов'язкових презентацій)

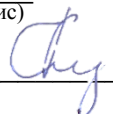
1. Предметна область: актуальність задачі, основні положення теорії класифікації.
2. Постановка задачі: мета, функціональні вимоги.
3. Аналіз інструментів та методів реалізації поставленої задачі.
4. Програмна реалізація, результати експерименту, порівняння результатів.
5. Висновки

6. Консультанти з випускної кваліфікаційної роботи із зазначенням розділів випускної кваліфікаційної роботи, що їх стосуються

Розділ	Консультант	Підпис, дата	
		Завдання видав	Завдання прийняв

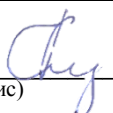
7. Дата видачі завдання 15 лютого 2022 року

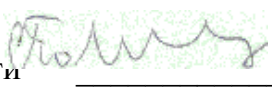
Керівник  / Сорока П. М. /  
(підпис) (ПІБ)

Завдання прийняв до виконання  / Синявська Є. Р. /  
(підпис) (ПІБ)

### КАЛЕНДАРНИЙ ПЛАН

Пор. №	Назва етапів випускної кваліфікаційної роботи	Термін виконання етапів випускної кваліфікаційної роботи	Примітка
1	Дослідження джерел та збір інформації для випускної кваліфікаційної роботи.	15.02.2022 - 22.02.2021	
2	Робота над розділом 1. Аналіз предметної області.	23.02.22 – 01.03.22	
3	Робота над розділом 2. Пошук даних та аналіз інструментів та методів для реалізації поставленої задачі	01.03.22– 07.03.22	
4	Робота над розділом 3. Попередня обробка зображень, створення датасету для навчання.	08.03.22 – 15.04.22	
5	Робота над розділом 3. Програмна реалізація нейронних мереж для класифікації	16.04.2022 - 8.05.2021	
6	Робота над розділом 3. Тестування програмного модулю, доповнення датасету. Аналіз отриманих результатів. Написання висновків.	9.05.2022 – 17.05.2022	
7	Оформлення пояснювальної записки, підготовка презентаційних матеріалів.	18.05.2022 – 29.05.2022	

Студент-дипломник  / Синявська Є. Р. /  
(підпис) (ПІБ)

Керівник випускної кваліфікаційної роботи  / Сорока П. М. /

### **Анотація**

**Синявська Євгенія Романівна** виконала випускню кваліфікаційну роботу на тему «Програмний модуль відстеження вирубки лісових масивів на основі супутникових даних методами машинного навчання» за спеціальністю 122 – «Комп'ютерні науки».

У цій випускній кваліфікаційній роботі проведено аналіз існуючих розв'язків класифікації лісів на основі даних дистанційного зондування Землі. Розроблено архітектуру, дерево функцій та узагальнену схему програмного модулю. Проведена тематична обробка даних ДЗЗ. Застосовані згорткові нейронні мережі U-Net, Linknet. Проведений порівняльний аналіз їх результатів.

**Ключові слова:** геоінформаційна система, згорткова нейронна мережа, семантична класифікація.

### **Summary**

The degree project: «Software module for tracking deforestation on the basis of satellite data by machine learning methods» has been completed by **Synyavska Yevheniya**, specialty 122 – «Computer Science».

This dissertation analyzes existing forest classification solutions based on remote sensing data. The architecture, function tree and generalized scheme of the software module are developed. Thematic processing of remote sensing data was created. Convolutional neural networks U-Net, Linknet were used. A comparative analysis of their results was made.

**Keywords:** geographic information system, convolutional neural network, semantic classification.

## ЗМІСТ

ВСТУП.....	4
РОЗДІЛ 1 АНАЛІТИЧНИЙ ОГЛЯД КЛАСИФІКАЦІЇ СУПУТНИКОВИХ ДАНИХ ЗА ДОПОМОГОЮ МЕТОДІВ МАШИННОГО НАВЧАННЯ.....	5
1.1. Область застосування дистанційного зондування Землі .....	5
1.2. Опис профілів зацікавлених сторін системи класифікації даних вирубки лісів на основі даних ДЗЗ.....	10
1.3. Аналіз існуючих розв’язків класифікації лісових масивів .....	10
1.4. Застосування згорткових нейронних мереж.....	13
1.5. Формулювання мети, основних задач кваліфікаційної роботи .	14
1.6. Функціональні та нефункціональні вимоги.....	15
РОЗДІЛ 2. РОЗРОБКА АРХІТЕКТУРИ КЛАСИФІКАЦІЇ ЛІСОВИХ МАСИВІВ ЗА ДОПОМОГОЮ МЕТОДІВ МАШИННОГО НАВЧАННЯ.....	17
2.1. Узагальнена структура системи класифікації даних ДЗЗ .....	17
2.2. Функціональний аналіз класифікації даних ДЗЗ .....	18
2.3. Узагальнене дерево функцій системи класифікації даних ДЗЗ.	19
2.4. Узагальнена архітектура системи класифікації даних.....	200
2.5. Детальний опис етапів .....	200
2.5.1. Отримання даних ДЗЗ.....	200
2.5.2. Обробка (дешифрування) даних ДЗЗ .....	211
2.5.3. Вибір нейронної мережі.....	266
2.5.4. Вибір функції активації .....	30
2.5.5. Навчання нейронної мережі .....	332
2.5.6. Аналіз отриманих результатів .....	33

РОЗДІЛ 3 СТВОРЕННЯ НЕЙРОННИХ МЕРЕЖ, ОПИС ТА РЕЗУЛЬТАТИ РОБОТИ ПРОГРАМИ.....	36
3.1. Попередня обробка вхідних даних .....	36
3.1.1. Формування маски для навчання нейронних мереж.....	38
3.2. Створення програмного модуля класифікації зображень за допомогою згорткових нейронних мереж.....	39
3.3. Аналіз результатів навчання з різними функціями активації....	41
3.3.1. Програмний модуль з Softplus .....	41
3.3.2. Програмний модуль з Softmax .....	46
3.4. Аналіз результатів тестування програми.....	51
ВИСНОВКИ.....	53
СПИСОК ВИКОРИСТАНОЇ ЛІТЕРАТУРИ.....	54
ДОДАТКИ.....	56

## ВСТУП

Не дивлячись на стрімкий розвиток у сфері науки та інформаційних технологій, екологічні проблеми, як і раніше, залишаються актуальними та все ще потребують дієвого вирішення. Тому науковий та технологічний прогрес не має оминати і сферу захисту планети від пагубного впливу людини.

Дослідження навколишнього середовища за допомогою дистанційного зондування – це складна і різнобічна область науки, яка перебуває на періоді бурхливого розвитку. Сучасні методи дистанційного зондування відкрили новий етап у сфері забезпечення інформацією різноманітних досліджень та розробок.

Наразі поверхню Землі аналізують більше тисячі космічних апаратів. Це підтверджує, що зондування Землі досить перспективний та дієвий напрямок для розвитку дослідження поверхні нашої планети. Завдяки відкритому доступу до цих даних велика кількість людей та корпорацій мають змогу відстежувати стан земель та об'єктів на них.

Використання супутників дистанційного зондування Землі надало змогу контролювати та виявляти критичні моменти поверхні на Землі, наприклад, виверження вулканів, зміни ландшафту, вирубка лісів тощо. Як результат, виникає необхідність створення різноманітних методів класифікації цих даних.

Проблема вирубки лісів актуальна для всіх континентів землі, однак найбільш гостро ця проблема стоїть в країнах Західної Європи, Південної Америки, Азії. Інтенсивне знищення лісів призводить до проблеми збезлісення.

Мета даної роботи полягає у розробці програмного модуля для відстеження вирубки лісових масивів на основі супутникових даних методами машинного навчання (МН).

## РОЗДІЛ 1 АНАЛІТИЧНИЙ ОГЛЯД КЛАСИФІКАЦІЇ СУПУТНИКОВИХ ДАНИХ ЗА ДОПОМОГОЮ МЕТОДІВ МАШИННОГО НАВЧАННЯ

### 1.1. Область застосування дистанційного зондування Землі

Лісові масиви є складними динамічними природними системами, межі яких постійно змінюються. Крім того, ліс – джерело цінної промислової сировини. Зважаючи на високу трудомісткість отримання інформації про склад лісів та їх екологічний стан наземними методами, особливо на великих площах, важлива роль в оцінюванні стану лісів, їх картографуванні та проведенні екологічного моніторингу належить дистанційним методам досліджень. Експлуатація лісових ресурсів, зокрема вирубка лісів, проводиться не завжди санкціоновано та раціонально. Прикладом цього є стан лісів Карпат. Для контролю за промисловим використанням і відновленням лісів здійснюється оперативний космічний моніторинг методами дистанційного зондування Землі (ДЗЗ).

Дистанційне зондування Землі (ДЗЗ) – це одержання інформації про будь-який об'єкт чи процес без прямого контакту з ними. У сучасному розумінні ДЗЗ полягає в тематичному аналізі як власного, так і штучно створеного випромінювання земної поверхні в межах від ультрафіолетового до радіохвильового діапазонів [1].

Сьогодні в космосі працюють десятки апаратів різних типів, що виконують збір даних різними дистанційними методами. Серед них значну роль відіграють комерційні апарати, знімки яких доступні для використання не тільки урядовим та військовим структурам, а й широкому колу користувачів в усьому світі.

Технічний прогрес в галузі космічного знімання пов'язаний з:

- підвищенням просторової роздільної здатності знімальних систем;
- розширенням спектрального діапазону зареєстрованих зображень та отриманням багатоспектральних знімків.

Дані, отримані шляхом дистанційного зондування землі з космосу та повітряного знімання, знаходять досить широке застосування в різних сферах діяльності:

1. створення та оновлення карт;
2. кадастр, планування та управління територіями;
3. екологічний та природоохоронний моніторинг;
4. оцінка стану сільськогосподарських культур, прогнозування врожаю;
5. контроль стану лісів, спостереження за вирубкою та оцінка наслідків лісових пожеж;
6. спостереження та прогнозування погоди, контроль кліматичних змін;
7. прогнозування та спостереження за стихійними лихами, оцінка наслідків;
8. геологічні дослідження, розвідка корисних копалин;
9. дослідження атмосфери та світового океану;
10. спостереження за льодовим становищем;
11. виявлення випадків незаконного судноплавства.

Космічний знімок є зафіксованим певним видом сенсорів електромагнітним випромінюванням. Як територіальний носій інформації виступає піксель – неподільний найменший елемент двовимірного зображення, що характеризується яскравістю – здатністю ділянки земної поверхні відбивати або поглинати світло певної довжини хвилі.

Найбільш перспективним для вирішення географічних, екологічних, технічних завдань є багатозональні космічні знімки високої роздільної здатності, у піксельній сукупності яких містяться відбивні властивості природних та антропогенних об'єктів.



Рисунок 1.1. – Знімок Landsat-8

На сьогоднішній день існує ціла низка сервісів (супутників та їх сенсорів), що надають космічні знімки з різною роздільною здатністю, періодичністю, кількістю спектральних каналів. Серед найбільш успішних проектів відзначаємо дані ДЗЗ, які отримують з супутників SPOT, IKONOS, QuickBird, Landsat, TERRA (платформа ASTER) та ін.



Рисунок 1.2. – Вигляд Landsat-8




Рисунок 1.3 – Ескіз КА Terra з мітками інструментів, виконаний в NASA [2]



Рисунок 1.4 – Знімок зі супутника Terra: зображення двох циклонів [3]

Система ДЗЗ, яка проводить вимірювання природного випромінювання, працює за схемою пасивного ДЗЗ. Відповідно, ця система може проводити знімання тільки тоді, коли природне випромінювання доступне:

- вдень – у видимому діапазоні;
- вдень і вночі – в тепловому інфрачервоному та мікрохвильовому.




Рисунок 1.5 – Схема пасивного ДЗЗ

Існує також друга схема ДЗЗ – активне. Воно діє таким чином, що прилад, який розміщений на супутнику, має джерело випромінювання, яке направляє на об'єкт дослідження, а потім вже відбите випромінювання фіксується супутником.

Переваги:

- зйомка може проводитися в будь-який час доби;
- можливий контроль над потоком випромінювання, який йде від супутника;
- можна використовувати довжини хвиль, котрі занадто слабо представлені в спектрах природних випромінювачів.



Рисунок 1.6 – Схема активного ДЗЗ

Зробивши короткий огляд, можна з впевненістю стверджувати, що методи дистанційного зондування Землі відкривають широкий спектр можливостей для оцінювання стану екосистеми та дослідження можливих змін. Натомість існує декілька проблем при використуванні даних ДЗЗ:

- висока вартість користування;
- недостатня якість технічної підтримки;
- недостатня точність і надійність інформації.

Незважаючи на ці недоліки, дистанційне зондування Землі залишається актуальним по сьогоднішній день. Більшість розвинених країн інвестують в розвиток цієї сфери.

## 1.2. Опис профілів зацікавлених сторін системи класифікації даних вирубки лісів на основі даних ДЗЗ

### 1. Внутрішні зацікавлені сторони:

- розробник системи;
- екологи;
- розробники системи ДЗЗ.

### 2. Зовнішні зацікавлені сторони:

- контролюючі органи (міністерство екології та природних ресурсів, Міністерство цифрової трансформації);
- державні органи (державне агентство лісових ресурсів, державна екологічна інспекція).

## 1.3. Аналіз існуючих розв'язків класифікації лісових масивів

Існує багато онлайн веб-додатків для аналізу поверхні Землі. Проблематика вибору полягає у їх доступності звичайному користувачу, вартість підписки, відповідність функціоналу до очікуваних сподівань користувача. У ході даної кваліфікаційної роботи була розглянута онлайн платформа Global Forest Watch [14].

Для глобального моніторингу заліснення та знеліснення Інститут світових ресурсів (World Resources Institute) у співпраці з багатьма науковими та громадськими організаціями, зокрема Google, USAID, Мерілендський університет і ESRI, створив відкриту онлайн-платформу Global Forest Watch, що базується на даних супутникових знімків Modis і Landsat та дозволяє у режимі, наближеному до реального часу, відстежувати зміни лісового покриву.

За допомогою картографічного інтерфейсу системи (рис. 1.7-1.10) можна виділити територію, часовий проміжок і отримати інформацію про площу втраченого лісового покриву та площу заліснених територій.

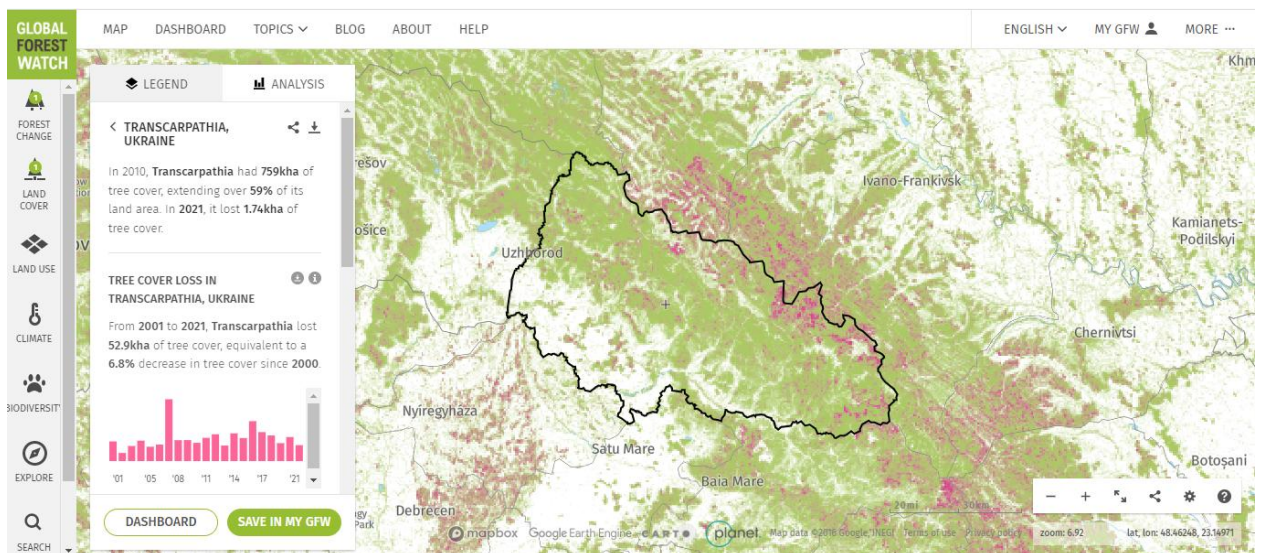


Рисунок 1.7 – Приклад застосування Global Forest Watch на Закарпатській області

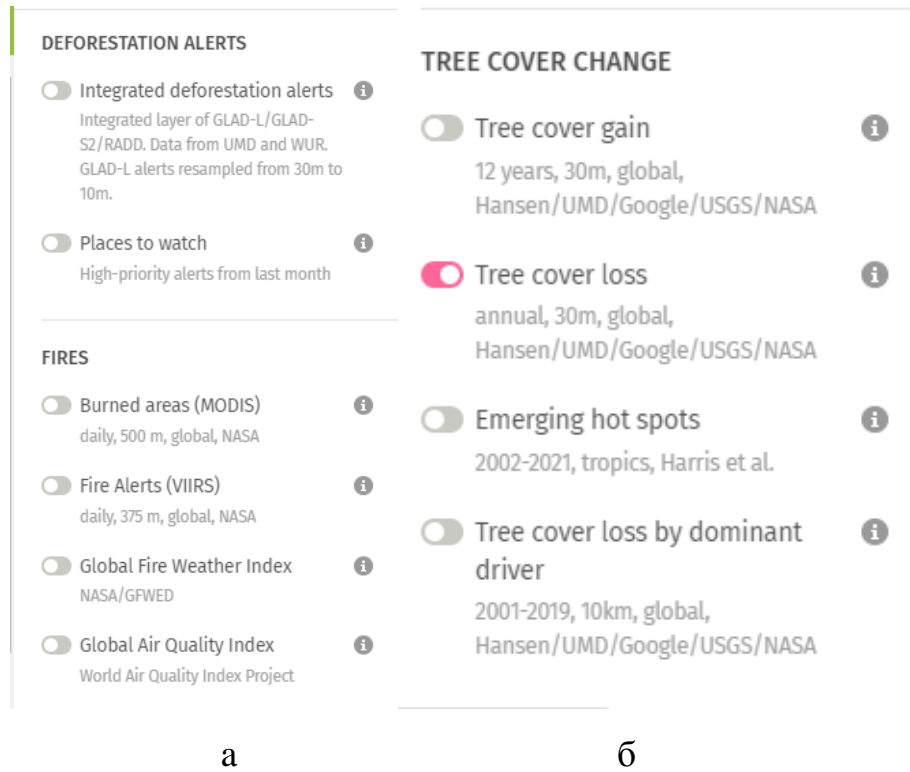


Рис. 1.8 – Інтерфейс FOREST CHANGE: а – залежність змін лісового покриття від пожеж; б – зміна лісового покриття

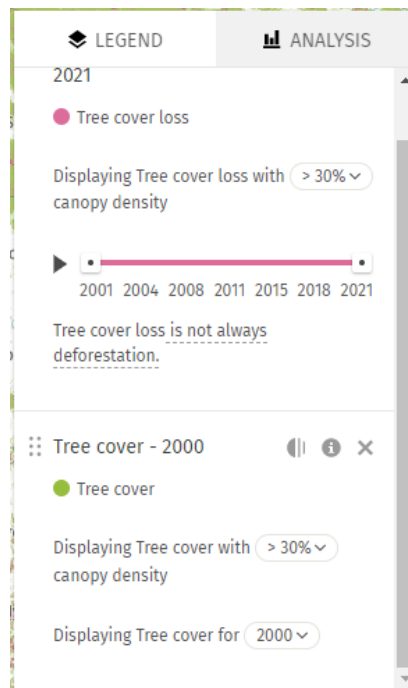


Рисунок 1.9 – Інтерфейс LEGEND

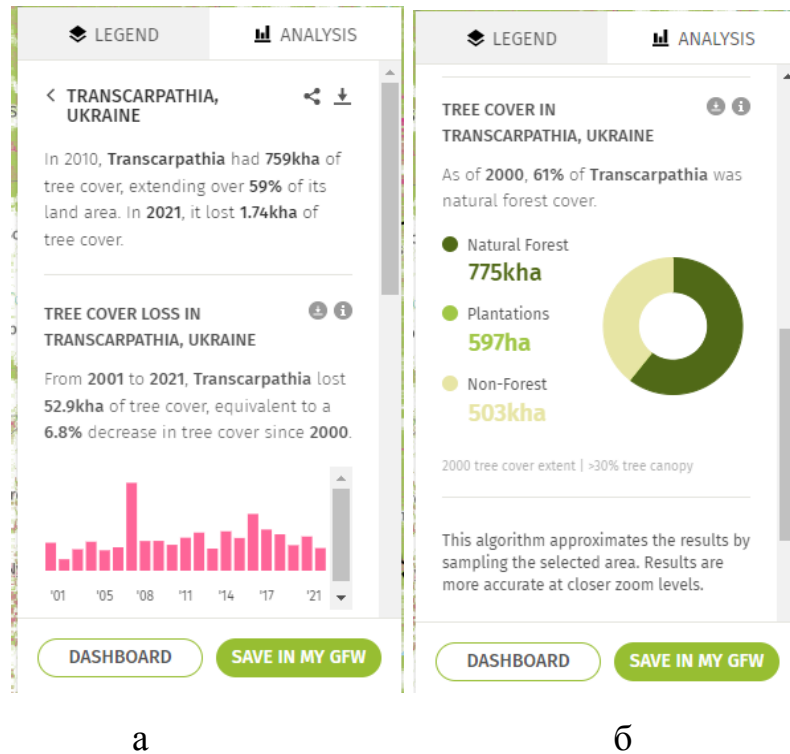


Рисунок 1.10 (а, б) – Інтерфейс ANALYSIS: а – статистика вирубки лісів обраної області; б – статистика даних лісового покриття обраної області

Після вибору території на карті, яка цікавить, кожен користувач може підписатися на оновлення даних на цю територію, у разі якщо будуть відбуватися зміни. Таким чином, система дозволяє, з одного боку, оцінювати рівень знеліснення у світовому масштабі, а з іншого – надає громадськості інструмент для контролю за нелегальними рубками лісів [15].

#### 1.4. Застосування згорткових нейронних мереж

Для задач розпізнавання графічних образів було розроблено теорію згорткових мереж, які наразі є поширеним засобом для даного класу задач в різноманітних сферах і показують хороші результати.

Доцільність використання методів машинного навчання для класифікації об'єктів на основі супутникових знімків пояснюється тим, що нейронні мережі обробляють дані з кращою точністю, ніж інші алгоритми розпізнавання.

Необхідність у різних методах НМ обумовлена потребою розпізнавання зображень з високою точністю та великою кількістю деталей. З кожним днем, якість знімків, зроблених новими супутниками зростає та відображає все більше елементів. Розвиток алгоритмів дозволяє розпізнавати нові типи та класи об'єктів за менший час.

Через велику кількість архітектур штучних нейронних мереж, з'являється складність у виборі найбільш придатної, яка матиме найкращі результати з максимальною точністю. Отже є необхідність у проведенні експериментів та порівнянні їх результатів, що займає досить багато часу.

Одною з ключових у використанні задач ДЗЗ є згоркова нейронна мережа. Хоча нейронні мережі прямого поширення можливо застосовувати, як для навчання ознак, так і для класифікації даних, застосування цієї архітектури до зображень є непрактичним. Було б необхідним дуже велике число нейронів, навіть у поверхневій (протилежній до глибинної) архітектурі, через дуже великі розміри входу, пов'язані з зображеннями, де кожен піксель є відповідною змінною.

Операція згортки дає змогу розв'язати цю проблему, оскільки вона зменшує кількість вільних параметрів, дозволяючи мережі бути глибшою за меншої кількості параметрів.

Згорткові нейронні мережі (ЗНМ, англ. convolutional neural network, CNN, ConvNet) – це клас глибинних штучних нейронних мереж прямого поширення, який застосовується до аналізу зображень.

### 1.5. Формулювання мети, основних задач кваліфікаційної роботи

Як було розглянуто у підрозділі 1.4, наявність великого вибору штучних нейронних мереж має свої переваги та недоліки. Це створює проблемний момент для остаточного вибору найефективнішого методу розв'язання задач класифікації зображень, пріоритет – знайти дієве рішення, яке займає найменше часу.

У даній роботі буде створений програмний продукт для класифікації лісових масивів декількома методами. У ньому будуть використані різні типи нейронних мереж та порівняна якість їх роботи та час, який витрачається на роботу програми для розв'язання завдання. Таким чином, буде знайдена найкраща штучна нейронна мережа для поставленої задачі.

*Метою кваліфікаційної роботи є класифікація даних ДЗЗ за допомогою методів машинного навчання та аналіз отриманих результатів. Для реалізації поставленої мети буде використано декілька нейронних мереж і серед них буде вибрана та, яка покаже найкращий результат за найкоротший час роботи програми. Вхідними даними для проведення дослідження будуть виступати знімки певних областей України. На цих зображеннях потрібно буде класифікувати лісові масиви за допомогою ШНМ.*

*Основними завданнями кваліфікаційної роботи є:*

- аналіз літератури про дешифрування даних дистанційного зондування Землі;
- визначення основної мети використання ДЗЗ в сфері лісового господарства;
- отримання та обробка даних ДЗЗ;
- написання програмного модулю із використанням нейронних мереж для розв'язання поставленої задачі;
- аналіз отриманих результатів.

*Об'єкт дослідження – класифікація даних ДЗЗ.*

*Предмет дослідження – класифікація даних дистанційного зондування Землі за допомогою нейронних мереж різної архітектури.*

## 1.6. Функціональні та нефункціональні вимоги

Функціональні:

- тематична обробка даних ДЗЗ:

- визначення меж земель лісових масивів на знімках;
- зменшення шумів на знімках;
- модифікація контрастності зображення ДЗЗ;
- класифікація лісових масивів на знімках:
  - розпізнавання лісових масивів;
  - визначення площі лісових масивів;

Нефункціональні:

- зменшення часу моніторингу території лісових масивів;
- визначення відсотку та швидкості розпізнавання лісових масивів на зображеннях;
- висока якість знімків ДЗЗ.

## РОЗДІЛ 2. РОЗРОБКА АРХІТЕКТУРИ КЛАСИФІКАЦІЇ ЛІСОВИХ МАСИВІВ ЗА ДОПОМОГОЮ МЕТОДІВ МАШИННОГО НАВЧАННЯ

### 2.1. Узагальнена структура системи класифікації даних ДЗЗ

Космічні супутники роблять знімки. Після чого, зображення зі супутників передаються у наземні центри.

Наступним етапом є первинна обробка знімків. Сюди входить тематична обробка зображень, а саме:

1. зменшення шумів;
2. зміна контрастності знімку;
3. виділення меж.

Ці етапи обробки необхідні для покращення якості зображення з метою розв'язання таких задач, як: знаходження площі ділянки, визначення конкретних меж земель тощо.

Наступний етап – вибір архітектури нейронної мережі. Архітектура нейронної мережі впливає на час виконання поставленої задачі та її якість. В ході виконання даної кваліфікаційної роботи буде використано декілька типів згорткових нейронних мереж для їх порівняння.

Далі здійснюється класифікація земель, виділення та віднесення ділянок лісу одного типу до певної групи. Цей етап може бути реалізований за допомогою різних способів машинного навчання: навчання з вчителем, навчання без вчителя. У першому випадку, визначається яскравість пікселів на знімку. Після їх порівняння з еталонними значеннями, вони об'єднуються в групи. Існує також декілька методів МН, які можуть застосовуватись для класифікації даних, такі як: метод опорних векторів, бінарна класифікація, класифікація за допомогою нейронних мереж та ін. В ході даної кваліфікаційної роботи буде розглядатись саме метод, пов'язаний з нейронними мережами. Це пояснюється тим, що існує можливість їх навчання. В результаті, можна досягнути хороших показників мінімізації «шумів» на зображеннях.

Завершальним етапом є аналіз отриманих результатів та їх порівняння.  
На рис. 2.1 зображена загальна схема системи.

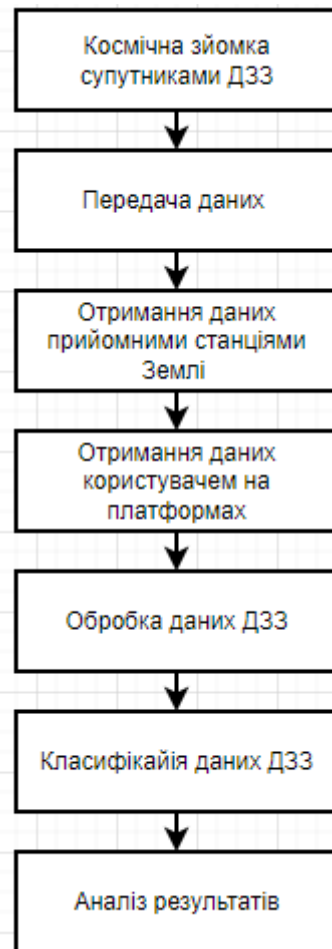


Рисунок 2.1. – Загальна схема системи класифікації даних ДЗЗ

## 2.2. Функціональний аналіз класифікації даних ДЗЗ

Система класифікації даних ДЗЗ складається з таких функцій:

- отримання даних з платформи Glovis;
- завантаження знімків у систему QGIS:
  - вхідні дані: зображення у форматі .TIF;
- тематична обробка даних:
  - зменшення шумів;
  - модифікація контрастності;
  - підвищення роздільної здатності;

- класифікація зображень за допомогою згорткових нейронних мереж:
  - вхідні дані: зображення;
  - вибір прикладу для навчання;
  - навчання мережі;
  - розрахунок помилки;
  - налаштування вагових коефіцієнтів (якщо значна помилка);
  - навчання завершено.
- аналіз отриманих результатів.

### 2.3. Узагальнене дерево функцій системи класифікації даних ДЗЗ

На рис. 2.2 зображено узагальнене дерево функцій системи.

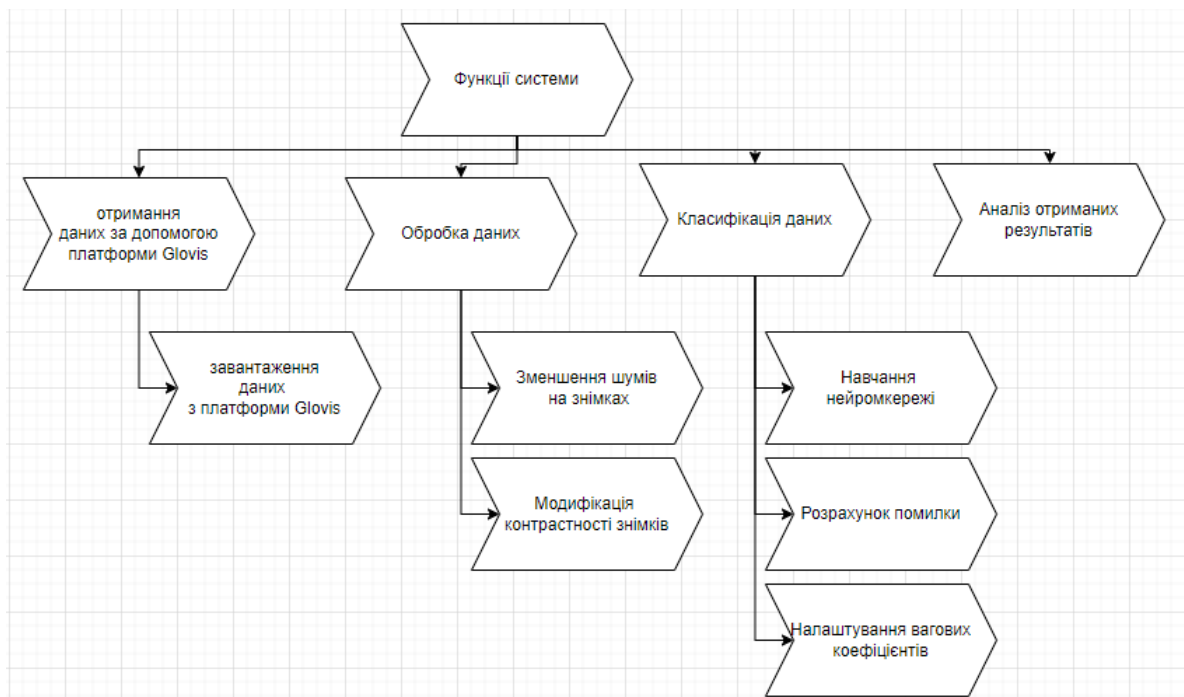


Рисунок 2.2 - Дерево функцій системи

## 2.4. Узагальнена архітектура системи класифікації даних

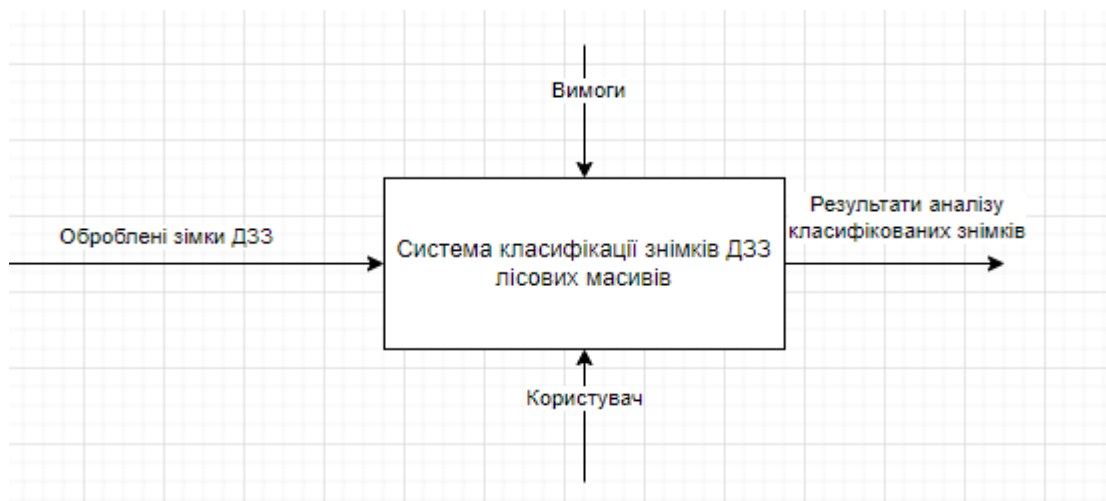


Рисунок 2.3. – Система класифікації у вигляді «чорної скриньки»

## 2.5. Детальний опис етапів

### 2.5.1. Отримання даних ДЗЗ

Для того щоб класифікувати дані, необхідно їх спочатку отримати зі супутників. Найбільш поширений спосіб передачі даних – неперервний радіозв'язок з приймаючими станціями.

Перший етап буде отримання даних ДЗЗ. Вхідними даними для розв'язання задачі будуть виступати растрові зображення. Також для визначення точності результатів роботи програми необхідно мати еталонні значення. Ці дані будуть порівнюватись зі значеннями, отриманими в результаті виконання програми. Готові знімки з вищою роздільною здатністю з об'єктами, які точно класифікуються можуть виступати в ролі еталонів. В якості ресурсу вхідних даних буде взято супутник Landsat-8. В ході даної роботи буде використано інтерфейс, який надає знімки Landsat у вільному доступі – Glovis.

Для тематичної обробки вхідних даних, в якості растрових зображень типу .TIF, буде використовуватись програмний додаток – QGIS. Ця програма застосовується для візуалізації, налаштування характеристик космічних зображень, зроблених за допомогою супутників.

QGIS (Quantum GIS) — вільне крос-платформове геоінформаційне програмне забезпечення з відкритим кодом. Серед вільних програмних продуктів ГІС є найбільш функціональним та зручним, що також підтримує інтеграцію з іншими вільними програмними продуктами, такими як PostGIS, GRASS та MapServer, а також величезного набору плагінів, створених користувачами та розробниками для вирішення на програмних мовах C++ або Python.

Геоінформаційна система (ГІС, англ. GIS) — це сукупність електронних карт з умовними позначеннями об'єктів на них, баз даних з інформацією про ці об'єкти та програмного забезпечення для зручної роботи з картами і базами як з єдиним цілим. За допомогою ГІС існує можливість інтегрувати всі дані, а потім візуалізувати їх та проаналізувати взаємозв'язки між ними, розробити моделі, прогнозу аналітику та планування, ґрунтуючись на цьому масиві даних. Але найважливішим є можливість приймати рішення на основі даних, що робить більш імовірним прийняття правильного рішення з урахуванням різних варіантів розвитку подій.

Геоінформаційні технології (ГІС-технології) — технологічна основа створення географічних інформаційних систем, які дозволяють реалізувати функціональні можливості ГІС. ГІС-технологія — це технологія, яка може застосовуватись за наявності чотирьох складових: люди, картографічне забезпечення, інформаційне забезпечення (дані, супутникові знімки) та програмне забезпечення (ГІС-пакети) [7].

### 2.5.2. Обробка (дешифрування) даних ДЗЗ

Дешифрування матеріалів дистанційного зондування Землі – це процес, за допомогою якого розкривається зміст знімків. Таким чином, під дешифруванням розуміють процес виявлення, розпізнавання та інтерпретації різної інформації за зображенням земної поверхні. При цьому спочатку виявляють, потім розпізнають географічні об'єкти, визначають їх якісні та

кількісні характеристики та відображають результати їх вивчення на знімку чи карті умовними знаками. Результати дешифрування залежать від оптичних і геометричних властивостей знімків, методів, які застосували, та рівня знань та досвіду користувача, який виконує дешифрування знімків [8].

При дешифруванні знімків аналізують фотографічні образи об'єкта, що мають низку розпізнавальних (дешифрувальних) ознак, тобто характерних особливостей, за якими об'єкти відрізняються один від одного. Ці ознаки можуть бути прямими або непрямими (опосередкованими).

Прямі дешифрувальні ознаки — це властивості самих об'єктів та їх зображень, які дозволяють безпосередньо визначити особливості і характеристики об'єктів земної поверхні.

Непрямі ознаки дешифрування ґрунтуються на різних взаємозалежностях між об'єктами і елементами земної поверхні. Часто непрямі ознаки вказують на наявність окремих властивостей об'єктів, які були не отримані при зйомці з огляду на географічні, фотографічні та геометричні особливості. Непрямі ознаки, які допомагають встановити природні закономірності і взаємозв'язки, називають непрямими ландшафтними. Другу групу непрямих ознак складають непрямі соціально-географічні ознаки, які ґрунтуються на зв'язку антропогенних і природних явищ і об'єктів [8].

Етапи обробки даних ДЗЗ можуть бути розділені на дві основні групи:

- попередня обробка космічних знімків – це комплекс операцій зі знімками, спрямований на усунення різних спотворень зображення. Спотворення можуть бути обумовлені: недосконалістю реєструючої апаратури; впливом атмосфери; перешкодами, пов'язаними з передачею зображень по каналах зв'язку; геометричними спотвореннями, пов'язаними з методом космічної зйомки; умовами освітлення підстильної поверхні; процесами фотохімічної обробки та аналого-цифрового перетворення зображень (при роботі з матеріалами фотографічної зйомки) та іншими факторами. Попередня обробка даних ДЗЗ включає в себе геометричну,

радіометричну, атмосферну корекцію зображення, географічну прив'язку знімка [8];

- тематична обробка космічних знімків — це розпізнавання об'єктів і явищ на космічних знімках на основі дешифрувальних ознак.

Попередня обробка [9]:

- Геометричне корегування – це усунення на зображенні геометричних викривлень (орторектифікація) і геоприв'язку.
- Радіометричне корегування або калібрування знімків – це калібрування значень вихідного сигналу знімального приладу та їх переведення в абсолютні значення альbedo і радіаційної температури. Знімки, що первісно отримуються із супутників, записані у вигляді так званих «сирих значень» яскравості DN (Digital Number). Дані в такому форматі не можна адекватно порівняти з даними інших зйомок.
- Фільтрація — це перетворення, яке дозволяє підсилити відтворення тих або інших об'єктів, зменшити небажане вуалювання, усунути інші випадкові перешкоди (шум).

Тематична обробка космічних знімків ДЗЗ об'єднує процедури отримання інформації з оброблених матеріалів. Цей процес здійснюється шляхом логічних і арифметичних операцій, класифікацій та інших методичних прийомів, у тому числі візуального дешифрування зображення.

До основних методів тематичної обробки належать:

- комбінування каналів;
- індексні зображення;
- аналіз головних компонент;
- метод спектрального поділу;
- класифікації.

Метод комбінування каналів супутникових знімків полягає у визначенні спектральних діапазонів, важливих для відображення тих чи інших об'єктів та синтезу відповідних спектральних каналів супутникових

знімків у кольорове зображення. Так, синтез каналів видимої частини спектра формує зображення, близьке до звичайної фотографії або того, що можна побачити людським оком. Об'єкти дешифрування будуть мати звичний та зрозумілий колір і, відповідно, вигляд, що може суттєво полегшити процес ідентифікації об'єктів на знімках. Така комбінація каналів називається природні кольори. Однак значна частина інформації буде залишатися прихованою за такої комбінації каналів, тому для виявлення таких об'єктів чи їх властивостей варто використовувати комбінацію каналів із застосуванням ближніх, середніх чи дальніх інфрачервоних діапазонів. Як правило, ці канали поєднують з одним чи декількома каналами видимого діапазону. У результаті формується псевдокольоровий знімок.

Метод створення індексних зображень – один із найпростіших та найпоширеніших методів дешифрування супутникових знімків, що також базується на спектральних особливостях об'єктів дослідження та фактично є математичною операцією з кількома спектральними каналами. Однак, на відміну від методу комбінування каналів, у результаті формується індексне зображення, піксель якого може набувати значення у певному визначеному діапазоні значень. Це дозволяє порівнювати між собою отримані у результаті індексні зображення на різні території чи зроблені у різні часові періоди. Одним з найпоширеніших індексів є нормалізований вегетаційний індекс NDVI, а також нормалізований водний індекс NDWI.

При застосуванні методу візуального дешифрування передбачається, що дешифрування виконує експерт, добре обізнаний з особливостями території і властивостями об'єктів, відображених на знімку.

Метод класифікації — як спосіб дешифрування космічних знімків, тобто розпізнання та виокремлення на космічних знімках будь-яких об'єктів [9]. Класифікація належить до автоматизованих способів дешифрування. У разі їх застосування користувачу не потрібно вручну обводити межі об'єктів, за нього це робить комп'ютерна програма.

Автоматичною класифікацією називають процес розбиття пікселів неперервного растрового зображення на категорії на основі їх спектральних значень, в результаті чого кожному пікселю присвоюється нове значення. За ступенем участі користувача в процесі автоматизованого дешифрування алгоритми класифікації поділяють на дві групи: класифікація без навчання (автономна класифікація, некерована класифікація, кластеризація) та класифікація з навчанням (керована класифікація) [9].

Якщо перед початком класифікації невідомо, скільки та які об'єкти є на знімку, застосовують класифікацію без навчання (некеровану класифікацію). Цей процес означає автоматичний розподіл пікселів зображення на підставі аналізу статистичного розподілу їх яскравості. Недоліком цієї класифікації є те, що потрібно виконувати дешифрування отриманих класів, щоб визначити, яким об'єктам зображення вони відповідають. Некеровану класифікацію часто використовують як попередній етап класифікації з навчанням.

Найбільш поширеними методами класифікації без навчання є такі:

1. ISODATA (Iterative Self-Organizing Data Analysis Technique) – ітераційна методика аналізу даних, що самоорганізується, яка заснована на кластерному аналізі. Основний параметр, що задається перед проведенням обчислень, — кількість кластерів, які необхідно отримати.

2. К-середніх відрізняється від методу ISODATA тим, що потребує початкового задання певної кількості середніх значень для формування вихідних класів, отже, цей метод використовують, коли об'єкти на знімку добре розрізняються [9].

Класифікацію з навчанням (керовану класифікацію) застосовують, коли наперед відома кількість класів об'єктів та їх типологічні особливості. У процесі цієї класифікації розподіл пікселів на класи здійснюють на основі порівняння значень характеристик кожного пікселя з еталонами (навчальними вибірками), які формують для кожного класу шляхом відбору пікселів з певним діапазоном характеристик відповідно до реальних об'єктів місцевості на знімку.

Класифікація з навчанням виконується в декілька етапів:

- визначення кількості класів та їхнього змісту;
- створення навчальних вибірок (користувацьких еталонів);
- перевірка якості навчальних вибірок;
- вибір алгоритму (способу) класифікації з навчанням;
- виконання класифікації;
- післякласифікаційна обробка карти класифікації;
- оцінка точності результатів класифікації.

### 2.5.3. Вибір нейронної мережі

В ході виконання даної кваліфікаційної роботи буде використано декілька видів згорткових нейронних мереж. В розділі 1.4 були описані переваги даної архітектури та необхідність її використання для розв'язання даного типу задач.

ЗНМ використовують порівняно мало попередньої обробки, в порівнянні з іншими алгоритмами класифікації зображень.

Ідея ЗНМ полягає в чергуванні згорткових шарів (англ. convolution layers) і субдискретизуючих шарів (англ. subsampling layers, верств підвибірки). Структура мережі – односпрямована (без зворотних зв'язків), багат шарова (рис. 2.5).




Рисунок 2.4 – Структура ЗНМ

Модель згорткової мережі складається з трьох типів шарів: згорткові (convolutional) шари, субдискретизуючі (subsampling, підвибірка) верстви і прошарки «звичайної» нейронної мережі – перцептрона.

Зображення, яке подається, виступає в якості вхідного шару. Значення вхідних пікселів зображення нормалізується для пришвидшення результатів навчання. Точні нормалізовані значення пікселів визначаються залежно від типу використовуваної функції активації.

Згортковий шар представляється у вигляді карт ознак. Операція згортки – це обчислення нового значення обраного пікселя, що є ключовим етапом в даній структурі. Для цього обчислення використовується матриця, яка має назву ядро згортки, інколи матриця згортки. Зазвичай, розмірність матриці є квадратною  $n \times n$ , де  $n$  – непарне число. Ядро згортки – ковзне вікно, яке проходить по всій області попередньої карти та виявляє певні ознаки об'єкту.

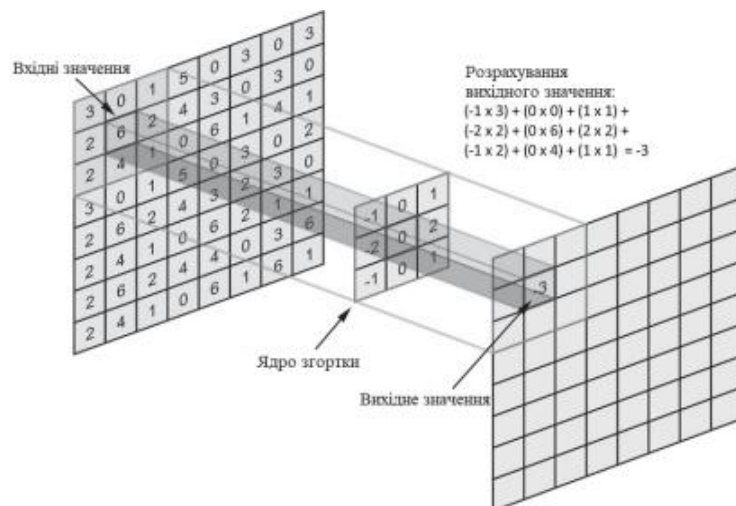


Рисунок 2.5 – Операція згортки

Для розв'язання задачі класифікації знімків ДЗЗ найчастіше використовують види нейронних мереж як U-Net та Link-Net.

U-Net – згорткова нейронна мережа, яка являє собою послідовність шарів згортки та пулінгу. Дана мережа навчається ковзним методом на невеликій кількості зображень [10].

Архітектура нейронної мережі U-Net наведена на рис. 2.6.

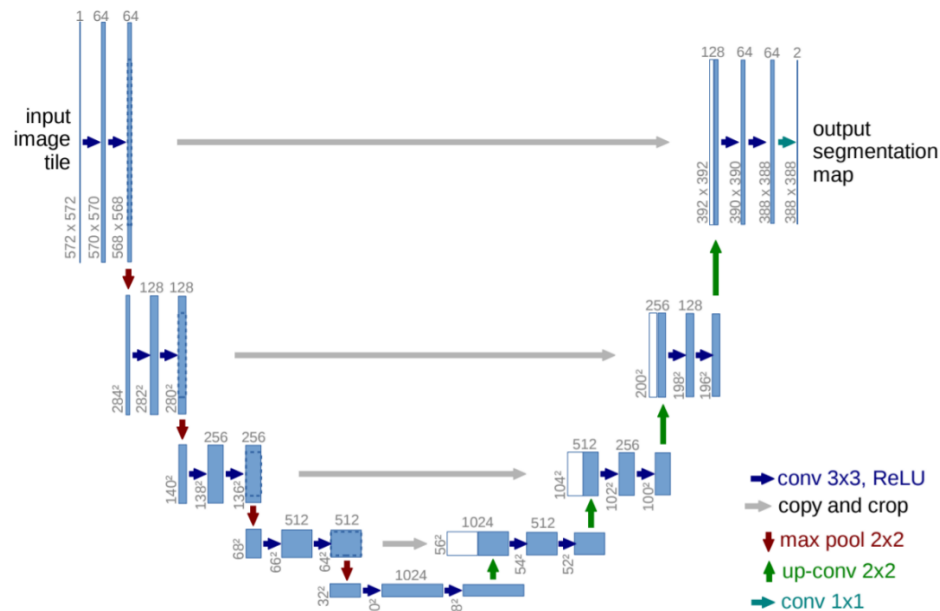


Рисунок 2.6 - Архітектура U-Net

Вона складається з частини зменшення розмірності (ліва частина) та частини збільшення розмірності (права частина). Частина зменшення розмірності відповідає типовій архітектурі згорткової мережі. Згорткова нейронна мережа складається з двох згорткових шарів, кожен з яких використовує ReLU в якості функції активації та шару субдискретизації.

Кожне синє поле відповідає багатоканальній карті функцій. Кількість каналів зазначено зверху над полем. Стрілки позначають різноманітні операції.

Навчання нейронної мережі відбувається методом стохастичного градієнтного спуску.

Метод стохастичного градієнтного спуску – метод, при якому значення кожного градієнта визначається з огляду на випадковий об'єкт з вибірки. Однією з переваг даного методу є відносно висока швидкість отримання результатів.

Архітектура LinkNet[11] є однією з передових архітектур штучних нейронних мереж для розпізнавання зображення, яка може використовуватись в системах автоматичного керування автомобілями чи для доповненої реальності.

Архітектура Link-Net наведена на рис. 2.7.

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 кількома 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 кодерів та декодерів. Де Initial Block є блоком вхідної обробки зображення що розпізнається. Блок складається з шарів Pool та Conv.

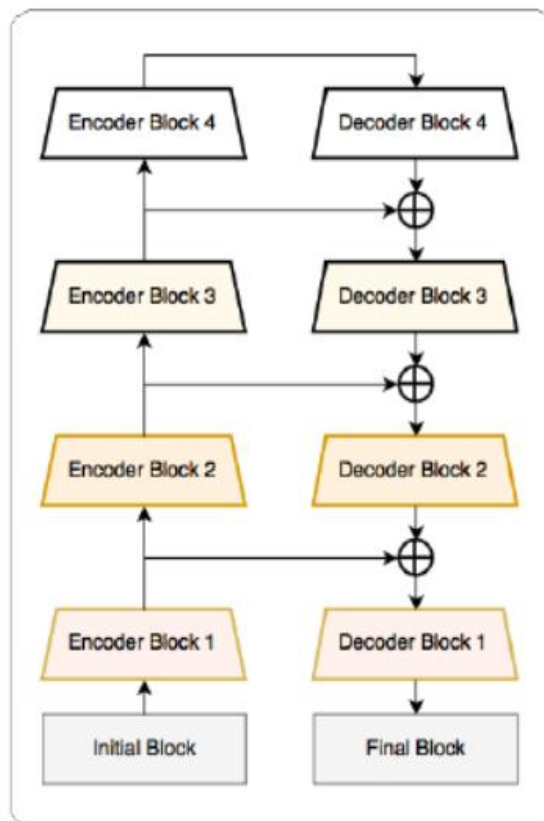


Рисунок 2.7 - Архітектура Link-Net

Головною відмінністю даної мережі від U-Net є те, що тут використовується операція додавання значень відповідних каналів. При тому, UNet використовує операцію конкатенації, при якому збільшується кількість каналів. На рис. 2.8 зображено схеми UNet та LinkNet та їх відмінність.




Рисунок 2.8 - Відмінність мережі UNet (зліва) та LinkNet (справа)

#### 2.5.4. Вибір функції активації

Одним з головних етапів розробки нейронної мережі є вибір функції активації. Відповідно до вибору, визначаються функціональні можливості мережі та метод її навчання. Існує велика кількість різноманітних функцій активації. Найбільш відомими є сигмоїдальна функція, гіперболічний тангенс, функція активації Softplus та функція м'якого максимуму. На рис. 2.9 наведено їх графіки.

$$f_i(x) = \frac{e^{x_i}}{\sum_{j=1}^J e^{x_j}}$$

(2.1)

де  $J$  – кількість класів.

Softmax – узагальнена логістична функція, яка складається з декількох класів, не лише двійкових [8]. Вона має здатність відображати виходи так, що загальна сума буде дорівнювати одиниці. Дана функція зазвичай використовується в кінцевому шарі класифікатора нейронної мережі. Softmax має наступний вигляд:

Softmax Activation Function




Рисунок 2.9 - Функція активації Softmax

Переваги використання Softmax:

- здатність обробляти декілька класів в моделях логістичної регресії;
- корисність для вихідних нейронів.

Softplus – одна з найефективніших функцій. Функція виглядає наступним чином:

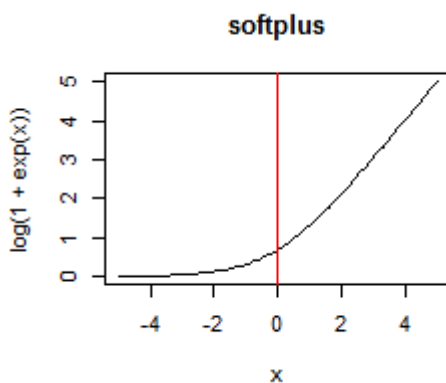


Рисунок 2.10 - Функція активації Softplus

$$f(x) = \log(\exp(x) + 1) \quad (2.2)$$

Переваги використання Softplus:

- відсутність ресурсоміських операцій;
- гладка безкінечно диференційована;
- відсікання непотрібних деталей;
- швидко навчається.

До недоліків можна віднести:

- не має 100% надійності виконання
- не центрована відносно 0.

Саме ці функції будуть використовуватись в ході написання даного програмного модулю. А також, буде порівнюватись коректність їх роботи на обох нейронних мережах.

#### 2.5.5. Навчання нейронної мережі

Наступним етапом є навчання нейронної мережі та класифікація даних ДЗЗ. Навчання відбувається за допомогою еталонних значень, вхідних даних, визначеної топології нейронної мережі та параметрів навчання.

Краще використовувати навчання з вчителем, при якому типам ландшафтно-екологічних систем задаються ділянки космічного знімку. Такий спосіб машинного навчання означає, що система має деяку множину пар вхід-вихід. На вхід подаються образи і на виході вони порівнюються із відповідними еталонними значеннями. Після цього параметри штучної нейронної мережі корегуються так, щоб відхилення від еталону стало якомога меншим.

Як було зазначено вище, вхідні дані являють собою знімки, зроблені супутниками, які потрібно класифікувати. А еталони – готові знімки з вищою роздільною здатністю з об'єктами, які точно класифікуються. Вхідний шар складається з трьох карт, де кожна відповідає одному з кольорів RGB (червоний, зелений, синій). Дані для навчання можна отримати за допомогою спеціальних програмних інтерфейсів, які є у вільному доступі. Як зазначалось вище, в ході цієї роботи дані будуть отримані з системи Glovis.

Щоб використовувати ці зображення для навчання мережі, попередньо дані будуть проходити тематичну обробку в системі QGIS.

Набір вхідних даних буде також необхідно попередньо перетворити в двовимірний масив, де кожному рядку буде відповідати значення окремого пікселя. Далі відбувається нормалізація та перетворення масивів в об'єкт навчання. Вхідні дані будуть розділені у пропорції 70/30. Де першій частині відповідає тренувальна вибірка, другій – тестувальна.

Для утворення маски вхідного зображення, буде використовуватись безкоштовний програмний продукт QGIS.

#### 2.5.6. Аналіз отриманих результатів

Останній етап дослідження – аналіз отриманих результатів та висновок, яка нейронна мережа впоралась зі завданням найкраще, надати числові характеристики часових проміжків виконання.

Основний показник якісного порівняння – F1-міра.

Бінарний класифікатор, який класифікує спостереження на позитивні та негативні класи, може мати свої передбачення, що підпадають під одну з наступних чотирьох категорій:

True Positive (TP): кількість позитивних класів, які були класифіковані правильно.

True Negative (TN): кількість класифікованих негативних класів.

Неправдивий результат (FP): кількість помилково класифікованих негативних класів.

Хибнонегативний (FN): кількість позитивних класів, які були неправильно класифіковані.

Категорії 1 і 2 - правильні передбачення, а 3 і 4 - неправильні передбачення. Прогноз моделі за категоріями 3 та 4 називається помилками типу I та типу II відповідно. Ці чотири категорії для кращого розуміння

можуть бути представлені в матриці, яка називається матрицею плутанини (Confusion Matrix), як показано на рис. 2.10.

		Actual	
		P	N
Pred	P	TP	FP
	N	FN	TN

Рисунок 2.11 – Матриця плутанини

Точність (Precision) - це відношення кількості справжніх позитивних результатів до загальної кількості передбачуваних позитивних результатів, як показано червоним прямокутником із заокругленими кутами у наведеній вище матриці плутанини. Це частка пророкованих позитивних результатів, які були правильно класифіковані. Він вимірює, як точна модель, коли вона класифікує спостереження як позитивне. Це також говорить нам, наскільки добре наша модель зменшує помилку типу I (хибне спрацьовування).

$$Precision = \frac{TP}{TP + FP} \quad (2.3)$$

Повнота - це відношення кількості істинних позитивних результатів до загальної кількості фактичних позитивних результатів, як показано синім прямокутником із заокругленими кутами у наведеній вище матриці плутанини. Це частка фактичних позитивних результатів, які були класифіковані правильно. Він вимірює, як добре модель нагадує фактичні позитивні класи. Це також говорить нам, наскільки добре наша модель зменшує помилку типу II (хибнонегативні результати). Його також називають чутливістю, оскільки він вимірює, наскільки чутлива модель до позитивного класу.

$$Recall = \frac{TP}{TP + FN} \quad (2.4)$$

Зацікавленість для обох метрик рівна. В цьому випадку нам потрібен збалансований компроміс між точністю та повнотою. Ось тут і з'являється показник  $f1$ . Показник  $f1$  – це середня гармонійна точність і повнота.

$$F1 = 2 \frac{Precision \times Recall}{Precision + Recall} \quad (2.5)$$

Як результат, отримана навчена нейронна мережа, яка може надалі використовуватись для задач класифікації вирубки лісових масивів.

## РОЗДІЛ 3 СТВОРЕННЯ НЕЙРОННИХ МЕРЕЖ, ОПИС ТА РЕЗУЛЬТАТИ РОБОТИ ПРОГРАМИ

### 3.1. Попередня обробка вхідних даних

Завдяки продукту Glovis було отримано архів із зображеннями, серед яких було обрано найкращий знімок для подальшої роботи. На рис. 3.1 зображено процес вибору знімку, який буде виступати в якості початкових даних.

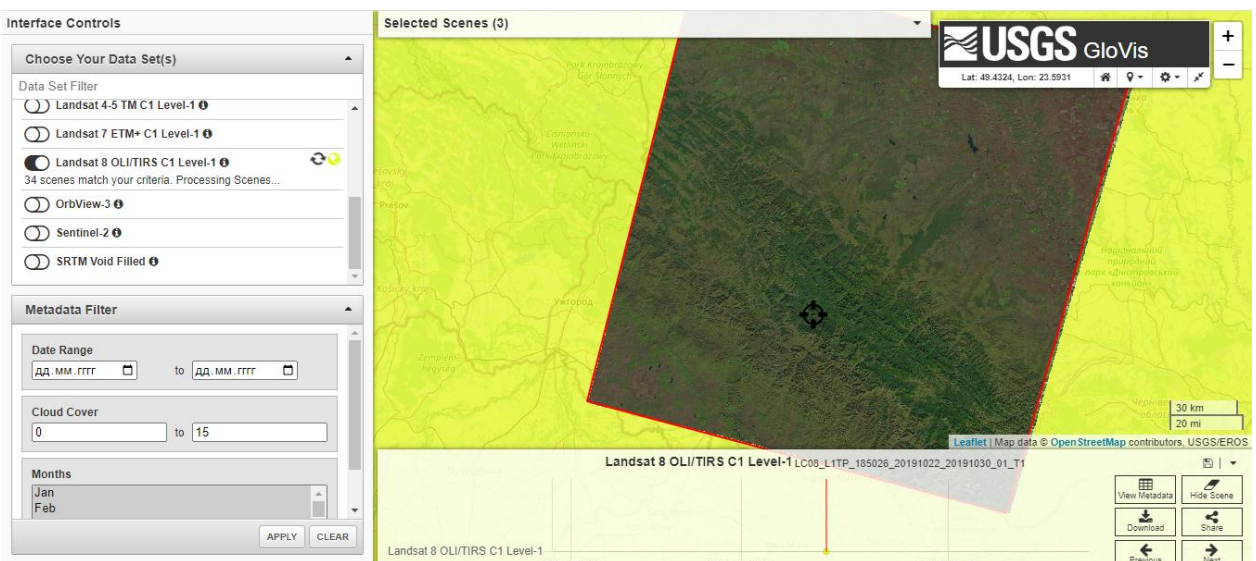


Рисунок 3.1 - Середовище Glovis

Після завантаження архіву, отримаємо набір растрових зображень різних каналів типу .TIF.

Приклад каналів даного фрагменту зображено на рис. 3.2.




Рисунок 3.2 - Фрагмент архіву зображень

Подальша робота з обробки зображень здійснюється в програмному додатку QGIS. Необхідно виконати попередню обробку знімків для покращення роздільної здатності.

Першим етапом обробки є злиття всіх каналів в один. Також за допомогою QGIS необхідно зменшити шум на зображенні від атмосферних неоднорідностей. Отримаємо зображення в натуральних кольорах. Результат наведено на рис. 3.3.




Рисунок 3.3 - Багатоспектральне зображення підвищеної роздільної здатності

Далі виконаємо тематичну обробку, а саме застосуємо до каналів шару червоний, зелений, синій канали 4, 5, 1 знімку відповідно. Здорова рослинність відображається у відтінках червоного, коричневого, оранжевого та зеленого. Ґрунти можуть виглядати зеленими або коричневими, урбанізовані території – білими, сірими та зелено-блакитними, яскраво блакитний колір може детектувати нещодавно вирубані території, а червоні – відновлення рослинності або розріджену рослинність. Чиста, глибока вода

буде виглядати дуже темно-синьою (майже чорною), якщо ж це мілководдя або у воді міститься велика кількість суспензій, то в кольорі переважатимуть світліші сині відтінки.



Рисунок 3.4 - Обраний фрагмент карти для порівняння – канали 1-2-3




Рисунок 3.5 - Обраний фрагмент карти для порівняння – канали 4-5-1

### 3.1.1. Формування маски для навчання нейронних мереж

Для отримання маски для навчання НМ виконаємо контрольовану класифікацію багатоканального знімку виділеної північно-східної області Прикарпаття методом мінімальних відстаней за допомогою модуля SCP. Обрано 7 тематичних класів (2 класи для рослинності, 2 для водних об'єктів та 1 для забудов, 1 для ґрунту, 1 для гір без рослинності, 1 для територій з

вирубкою). Для кожного класу потрібно обрати еталони. Еталони визначають якість навчальної вибірки та, як наслідок, точність контрольованої класифікації.

Отриманий знімок перетворюється на бінарний растр таким чином, що всі класи, що відносяться до вирубки, позначені білим кольором, а інші – чорним (рис. 3.6). Таким чином, отримується бінарне зображення – маска, яка разом з багатоканальним знімком (рис. 3.7) буде використовуватись для навчання нейронних мереж.




Рисунок 3.6 - Бінарні маски обраних територій




Рисунок 3.7 - Багатоканальні знімки обраних територій

### 3.2. Створення програмного модулю класифікації зображень за допомогою згорткових нейронних мереж

В ході даної роботи створено один програмний модуль мовою програмування Python.

При розробки визначеного програмного модулю були використані бібліотеки, наведені на рис. 3.8.

```

import tensorflow as tf
import segmentation_models as sm
import glob
import cv2
import os
import numpy as np
from matplotlib import pyplot as plt
import keras
import pandas as pd
from datetime import datetime

from keras.utils import normalize
from keras.metrics import MeanIoU

```

Рисунок 3.8 – Перелік використаних бібліотек

Для роботи із зображеннями в першу чергу необхідно зчитати багатоканальні зображення та відповідні маски, записати їх у масиви.

Виділимо 30% даних для тестування за допомогою методу `train_test_split`, зазначимо в аргументах `test_size=0.3` – 30% на тестування, `random_state=0` – не перемішувати масиви зображень.

Визначимо кількість класів - 2 класи, `n_classes=2`.

Зазначимо функції активації `SoftPlus` та `SoftMax`,

Визначимо оптимізатор `Adam`. `Adam` – один з найефективніших алгоритмів оптимізації. Він дозволяє обновлювати ваги ітеративно на основі навчених даних, невелика потреба в пам'яті навіть при роботі з великим обсягом даних:

```
optimizer = tf.keras.optimizers.Adam(LR)
```

Для оцінки ефективності роботи використовується значення точності F1.

Створення та компіляція моделей `U-Net` та `LinkNet`. Для процесу навчання було обрано 100 епох та 5 груп (батчів).

Навчені моделі зберігаються у файли для подальшого опрацювання.

Далі побудуємо графіки та виведення результатів навчання для кожної мережі.

Випадковим чином обирається зображення для тестування навченості мереж U-Net та LinkNet.

### 3.3. Аналіз результатів навчання з різними функціями активації

#### 3.3.1. Програмний модуль з Softplus

На рис. 3.9-3.10 зображено результати навчання мережі U-Net на перших 5-ти та на останніх 5-ти епохах.

```
Epoch 1/100
6/6 [=====] - 20s 2s/step - loss: 0.7493 - f1-score: 0.0704 - val_loss: 9.9500 - val_f1-score: 0.1856
Epoch 2/100
6/6 [=====] - 11s 2s/step - loss: 0.5495 - f1-score: 0.0923 - val_loss: 1.9471 - val_f1-score: 0.5401
Epoch 3/100
6/6 [=====] - 12s 2s/step - loss: 0.4559 - f1-score: 0.1773 - val_loss: 1.4921 - val_f1-score: 0.5174
Epoch 4/100
6/6 [=====] - 11s 2s/step - loss: 0.4124 - f1-score: 0.2799 - val_loss: nan - val_f1-score: 0.4647
Epoch 5/100
6/6 [=====] - 12s 2s/step - loss: 0.3946 - f1-score: 0.3288 - val_loss: nan - val_f1-score: 0.3928
Epoch 6/100
```

Рисунок 3.9 - Результати U-Net на перших 5-ти епохах, Softplus

```
Epoch 95/100
6/6 [=====] - 12s 2s/step - loss: 0.2532 - f1-score: 0.7451 - val_loss: 0.3697 - val_f1-score: 0.6333
Epoch 96/100
6/6 [=====] - 12s 2s/step - loss: 0.2467 - f1-score: 0.7609 - val_loss: 0.3766 - val_f1-score: 0.6262
Epoch 97/100
6/6 [=====] - 12s 2s/step - loss: 0.2425 - f1-score: 0.7655 - val_loss: 0.3701 - val_f1-score: 0.6202
Epoch 98/100
6/6 [=====] - 12s 2s/step - loss: 0.2449 - f1-score: 0.7538 - val_loss: 0.3754 - val_f1-score: 0.6089
Epoch 99/100
6/6 [=====] - 12s 2s/step - loss: 0.2387 - f1-score: 0.7671 - val_loss: 0.3800 - val_f1-score: 0.6029
Epoch 100/100
6/6 [=====] - 11s 2s/step - loss: 0.2322 - f1-score: 0.7763 - val_loss: 0.3881 - val_f1-score: 0.5913
```

Рисунок 3.10 - Результати U-Net на останніх 5-ти, Softplus

Загальний час виконання програми Unet time: 0:20:02.128481

Отримаємо графіки, зображені на рис. 3.12-3.13, для демонстрації результатів навчання.




Рисунок 3.12 – Графік втрат навчання та тестування U-Net



Рисунок 3.13 – Графік результатів тестування та навчання U-Net

На мережі U-Net функція Softplus спрацювала доволі нестабільно. 80 епоха – стрибки втрат на негативний стрибок значення точності.

На рис. 3.14-3.15 результати навчання мережі LinkNet на перших 5-ти та на останніх 5-ти епохах.

```
Epoch 1/100
5/6 [=====] - 21s 2s/step - loss: 1.9894 - f1-score: 0.3161 - val_loss: 1.2456 - val_f1-score: 0.4564
Epoch 2/100
5/6 [=====] - 9s 1s/step - loss: 1.9213 - f1-score: 0.3102 - val_loss: 1.1968 - val_f1-score: 0.4143
Epoch 3/100
5/6 [=====] - 9s 1s/step - loss: 1.8538 - f1-score: 0.3010 - val_loss: 1.1101 - val_f1-score: 0.3457
Epoch 4/100
5/6 [=====] - 9s 2s/step - loss: 1.7739 - f1-score: 0.2909 - val_loss: 1.0431 - val_f1-score: 0.2717
Epoch 5/100
5/6 [=====] - 9s 2s/step - loss: 1.7002 - f1-score: 0.2834 - val_loss: 1.0065 - val_f1-score: 0.2096
```

Рисунок 3.14 - Результати LinkNet на перших 5-ти епохах, Softplus

```
Epoch 95/100
5/6 [=====] - 9s 1s/step - loss: 0.7526 - f1-score: 0.1215 - val_loss: 0.7219 - val_f1-score: 0.0678
Epoch 96/100
5/6 [=====] - 9s 2s/step - loss: 0.7483 - f1-score: 0.1216 - val_loss: 0.7209 - val_f1-score: 0.0699
Epoch 97/100
5/6 [=====] - 9s 2s/step - loss: 0.7546 - f1-score: 0.1204 - val_loss: 0.7153 - val_f1-score: 0.0689
Epoch 98/100
5/6 [=====] - 9s 1s/step - loss: 0.7505 - f1-score: 0.1190 - val_loss: 0.7116 - val_f1-score: 0.0682
Epoch 99/100
5/6 [=====] - 9s 1s/step - loss: 0.7473 - f1-score: 0.1192 - val_loss: 0.7111 - val_f1-score: 0.0697
Epoch 100/100
5/6 [=====] - 9s 1s/step - loss: 0.7481 - f1-score: 0.1171 - val_loss: 0.7137 - val_f1-score: 0.0702
linknet execution time is: 0:15:00.413383
```

Рисунок 3.15 Результати LinkNet на останніх 5-ти епохах, Softplus

Загальний час виконання програми Linknet time: 0:15:00.413383

Графіки втрат та точності мережі LinkNet зображені на рис. 3.16 для візуалізації результатів навчання.

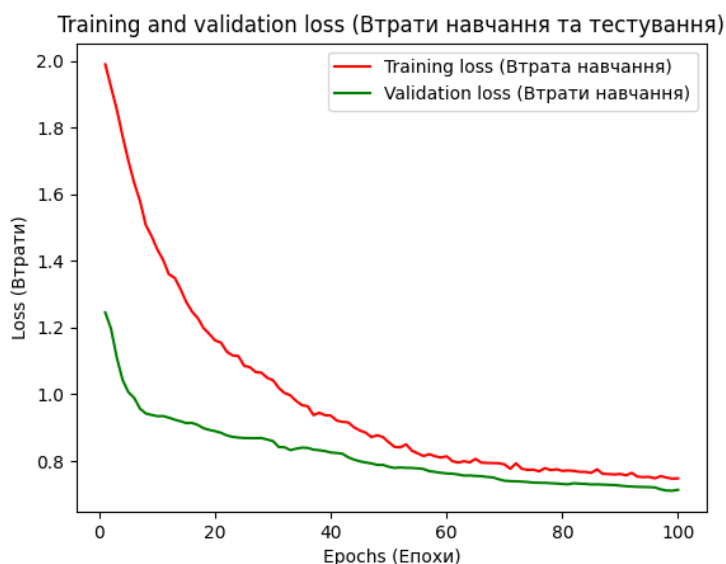


Рисунок 3.16 – Графік втрат навчання та тестування U-Net

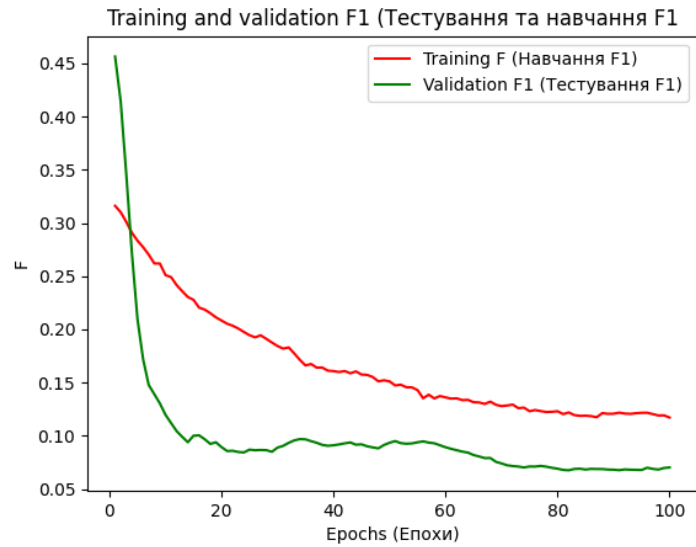


Рисунок 3.17 – Графік результатів тестування та навчання U-Net

З графіку на рис. 3.17 бачимо, що навчання не дало позитивного результату.

Результати роботи програми з функцією активації Softplus наведені в табл. 3.1.

Таблиця 3.1 Результати роботи програми з функцією активації Softplus

Нейронна мережа	Час (хв.)	Значення втрати (loss)	Значення точності (F1)
U-Net	20:02	0,2322	0,7763
LinkNet	15:00	0,7481	0,1171

На рис. 3.18-3.22 наведено тестове зображення та результати роботи мереж.

Testing Image




Рисунок 3.18 – Тестове зображення

Testing Label




Рисунок 3.19 – Маска тестового зображення

Unet result




Рисунок 3.20 – Результати класифікації U-net

Linknet result




Рисунок 3.21 – Результати класифікації Linknet

### 3.3.2. Програмний модуль з Softmax

На рис. 3.22-3.23 зображено результати навчання мережі U-Net на перших 5-ти та на останніх 5-ти епохах.

```
Epoch 1/100
6/6 [=====] - 20s 2s/step - loss: 1.1798 - f1-score: 0.3615 - val_loss: 42.1282 - val_f1-score: 0.1362
Epoch 2/100
6/6 [=====] - 11s 2s/step - loss: 0.6842 - f1-score: 0.4460 - val_loss: 5.2814 - val_f1-score: 0.4983
Epoch 3/100
6/6 [=====] - 11s 2s/step - loss: 0.5319 - f1-score: 0.4920 - val_loss: 2.5836 - val_f1-score: 0.4988
Epoch 4/100
6/6 [=====] - 11s 2s/step - loss: 0.4766 - f1-score: 0.5132 - val_loss: 2.8641 - val_f1-score: 0.4967
Epoch 5/100
6/6 [=====] - 11s 2s/step - loss: 0.4430 - f1-score: 0.5175 - val_loss: 1.6946 - val_f1-score: 0.4956
Epoch 6/100
```

Рис. 3.22 - Результати U-Net на перших 5-ти епохах, Softmax

```
Epoch 95/100
6/6 [=====] - 13s 2s/step - loss: 0.2678 - f1-score: 0.6637 - val_loss: 0.4125 - val_f1-score: 0.5702
Epoch 96/100
6/6 [=====] - 13s 2s/step - loss: 0.2660 - f1-score: 0.6689 - val_loss: 0.4034 - val_f1-score: 0.5704
Epoch 97/100
6/6 [=====] - 13s 2s/step - loss: 0.2655 - f1-score: 0.6753 - val_loss: 0.4470 - val_f1-score: 0.5550
Epoch 98/100
6/6 [=====] - 13s 2s/step - loss: 0.2560 - f1-score: 0.6795 - val_loss: 0.4081 - val_f1-score: 0.5672
Epoch 99/100
6/6 [=====] - 13s 2s/step - loss: 0.2519 - f1-score: 0.6867 - val_loss: 0.4018 - val_f1-score: 0.5665
Epoch 100/100
6/6 [=====] - 13s 2s/step - loss: 0.2514 - f1-score: 0.6885 - val_loss: 0.3858 - val_f1-score: 0.5662
```

Рис. 3.23 - Результати U-Net на останніх 5-ти епохах, Softmax

Загальний час виконання програми Unet time: 0:19:35.539522

Візуалізація результатів навчання рис. 3.24-3.25.



Рисунок 3.24 - Графік втрат навчання та тестування U-Net



Рисунок 3.25 - Графік результатів тестування та навчання U-Net

На рис. 3.26-3.27 зображено результати навчання мережі Linknet на перших 5-ти та на останніх 5-ти епохах.

```

Epoch 1/100
6/6 [=====] - 19s 2s/step - loss: 0.8552 - f1-score: 0.4038 - val_loss: 0.8220 - val_f1-score: 0.4235
Epoch 2/100
6/6 [=====] - 9s 1s/step - loss: 0.8462 - f1-score: 0.4115 - val_loss: 0.8425 - val_f1-score: 0.4029
Epoch 3/100
6/6 [=====] - 8s 1s/step - loss: 0.8394 - f1-score: 0.4178 - val_loss: 0.8673 - val_f1-score: 0.3817
Epoch 4/100
6/6 [=====] - 8s 1s/step - loss: 0.8320 - f1-score: 0.4225 - val_loss: 0.8957 - val_f1-score: 0.3621
Epoch 5/100
6/6 [=====] - 8s 1s/step - loss: 0.8249 - f1-score: 0.4289 - val_loss: 0.9244 - val_f1-score: 0.3475

```

Рисунок 3.26 - Результати Linknet на перших 5-ти епохах, Softmax

```

Epoch 95/100
6/6 [=====] - 9s 2s/step - loss: 0.7060 - f1-score: 0.6375 - val_loss: 0.7625 - val_f1-score: 0.5429
Epoch 96/100
6/6 [=====] - 9s 2s/step - loss: 0.7029 - f1-score: 0.6413 - val_loss: 0.7623 - val_f1-score: 0.5438
Epoch 97/100
6/6 [=====] - 9s 2s/step - loss: 0.7022 - f1-score: 0.6431 - val_loss: 0.7629 - val_f1-score: 0.5435
Epoch 98/100
6/6 [=====] - 9s 2s/step - loss: 0.7037 - f1-score: 0.6425 - val_loss: 0.7633 - val_f1-score: 0.5436
Epoch 99/100
6/6 [=====] - 9s 2s/step - loss: 0.7037 - f1-score: 0.6398 - val_loss: 0.7634 - val_f1-score: 0.5442
Epoch 100/100
6/6 [=====] - 10s 2s/step - loss: 0.6991 - f1-score: 0.6500 - val_loss: 0.7633 - val_f1-score: 0.5451

```

Рисунок 3.27 - Результати Linknet на останніх 5-ти епохах, Softmax

Загальний час виконання програми Linknet time: 0:15:31.414277

Візуалізація результатів навчання на рис. 3.28-3.29.




Рисунок 3.28 - Графік втрат навчання та тестування Linknet




Рисунок 3.29 – Графік результатів тестування та навчання Linknet

Результати роботи програми з функцією активації Softmax наведені в табл. 3.2.

Таблиця 3.2 Результати роботи програми з функцією активації Softmax

Нейронна мережа	Час (хв.)	Значення втрати (loss)	Значення точності (F1)
U-Net	19:35	0,2514	0,6885
LinkNet	15:00	0,6991	0,6500

На рис. 3.18-3.22 наведено тестове зображення та результати роботи мереж.

Testing Image




Рисунок 3.30 – Тестове зображення

Testing Label




Рисунок 3.31 – Маска тестового зображення

Unet result




Рисунок 3.32 – Результати класифікації U-net




Рис. 3.21 – Результати класифікації Linknet

#### 3.4. Аналіз результатів тестування програми

В табл. 3.3 порівняння результатів роботи нейронних мереж Linknet та U-net з двома функціями активації.

Таблиця 3.3 Порівняння результатів роботи модуля з функціями активації Softplus та Softmax

	Softplus			Softmax		
	Час (хв.)	Значення втрати (loss)	Значення точності (F1)	Час (хв.)	Значення втрати (loss)	Значення точності (F1)
U-Net	20:02	0,2322	0,7763	19:35	0,2514	0,6885
LinkNet	15:00	0,7481	0,1171	15:00	0,6991	0,6500

Аналізуючи таблицю, можна зробити висновок, що мережі U-Net та LinkNet навчаються майже однаковий час, незважаючи на обрану функцію активації. Але результативність – значення точності F1 – суттєво різняться. Функція Softmax показала себе краще та стабільніше ( $F1 > 0,5$ ). Результати Softplus неоднозначні. Функція гарно спрацювала на мережі U-Net ( $F1 > 0,5$ ), але на мережі LinkNet результат точності незадовільний ( $F1 < 0,5$ ).

Отже для подальшої класифікації доцільно застосовувати функцію активації Softmax.

Таблиця 3.4 Порівняння результатів роботи модуля з функцією активації Softmax

	Softmax
	Значення точності (F1)
U-Net	0,6885
LinkNet	0,6500

## ВИСНОВКИ

В кваліфікаційній роботі розглянуто основні сфери використання даних дистанційного зондування Землі. Здійснено обробку даних ДЗЗ за допомогою програмного додатку QGIS. Обробка первинна: зменшення шумів, зміна контрастності знімків, виділення меж. Обробка тематична: класифікація знімків.

Створено дві нейронні мережі U-Net та LinkNet для бінарної класифікації стану лісових масивів, а саме вирубки лісів. Використано функції активації Softplus та Softmax. Наведено порівняння їх результатів

Визначено, що нейронна мережа U-net здатна краще обробляти дані щодо класифікації стану лісових масивів, порівняно з мережею LinkNet.

Показано, що функція активації Softmax гарантує вищі та стабільні значення точності.

Результати дослідження даної кваліфікаційної роботи можна вдосконалювати та використовувати для реального моніторингу стану лісу екологами, контролюючими органами, державними органами та іншими зацікавленими сторонами.

## СПИСОК ВИКОРИСТАНОЇ ЛІТЕРАТУРИ

1. Основи дистанційного зондування Землі : історія та практичне застосування : навч. посіб. / С.О. Довгий, В.І. Лялько, С.М. Бабійчук, Т.Л. Кучма, О.В. Томченко, Л.Я. Юрків. – К. : Інститут обдарованої дитини НАПН України, 2019. – 316 с.
2. Терра (супутник) [Електронний ресурс] // Матеріал из Википедии – свободной энциклопедии. – Режим доступу до ресурсу: [https://ru.wikipedia.org/wiki/Терра\\_\(супутник\)](https://ru.wikipedia.org/wiki/Терра_(супутник)).
3. Terra Image Gallery [Електронний ресурс] - Режим доступу до ресурсу: [https://www.nasa.gov/mission\\_pages/terra/images/index.html](https://www.nasa.gov/mission_pages/terra/images/index.html).
4. Le Cun, Y., Kavukcuoglu, K.. and Farabet, C. (2010). Convolutional Networks and Applications in Vision. Proceedings of 2010 IEEE International Symposium on Circuitsc and Systems.
5. Gonzalez, R. and Woods, R. (2008). Digital Image Processing, Pearson Prentice Hall, 954 p.
6. LeCun, Y. and Bengio, Y. (1995). Convolutional networks for images, speech and time series, The handbook of brain theory and neural networ.
7. Mahoney, C. et al. Forest Attribute Mapping Framework: A Pilot Study in a Northern Boreal Forest, Northwest Territories, Canada//Remote sensing, 2018. – Т. 10, № 9 – С. 1338.
8. Системний аналіз та проектування ГІС. – Електронний навчальний посібник /Є.М. Крижановський, В.Б. Мокін, А.Р. Ящолт, Л.М. Скорина. – Вінниця : ВНТУ, 2015. – 127 с.
9. Прасул Ю.І., Копанішина К.М. Дистанційне зондування Землі. Робота з аеро- та космознімками. – Харків : Форт, 2009. – 51 с.
10. Первинна обробка (нормалізація) даних ДЗЗ [Електронний ресурс] – Режим доступу до ресурсу: <https://helpiks.org/6-84343.html>.

11. Роннебергер Олаф, Фішер Філіпп, Брокс Томас (2015). U-Net: згорткові мережі для біомедичної сегментації зображень. Енциклопедія. [site:uk.wikisko.ru](http://site:uk.wikisko.ru)
12. Підготовлений набір даних Linknet [//https://codeac29.github.io/projects/linknet /index.html](https://codeac29.github.io/projects/linknet/index.html)
13. Global Forest Watch [Електронний ресурс] – Режим доступу до ресурсу: <https://www.globalforestwatch.org/map>.
14. Hansen, Matthew; Popatov, Peter; et al. (2013). «High-Resolution Global Maps of 21st-Century Forest Cover Change». Science. 342 (6160): 850-853. doi:10.1126 /science.1244693.

## ДОДАТКИ

```
import tensorflow as tf
import segmentation_models as sm
import glob
import cv2
import os
import numpy as np
from matplotlib import pyplot as plt
import keras
import pandas as pd
from datetime import datetime
from keras.utils import normalize
xsize = 128
ysize= 128
n_classes=2
train_images = []
for directory_path in glob.glob("input/images/"):
    for img_path in glob.glob(os.path.join(directory_path, "*.tif")):
        image = cv2.imread(img_path, 1)
        image = cv2.resize(img, (ysize, xsize))
        train_images.append(img)

Images_tr = np.array(Images_tr)

masks_tr = []
for directory_path in glob.glob("input/label/"):
    for mask_path in glob.glob(os.path.join(directory_path, "*.tif")):
        mask = cv2.imread(mask_path, 0)
```

```

mask = cv2.resize(mask, (ysize, xsize), interpolation =
cv2.INTER_NEAREST) train_masks.append(mask)

```

```

masks_tr = np.array(train_masks)

```

```

from sklearn.preprocessing import LabelEncoder

```

```

labelencoder = LabelEncoder() #####створити мітку класу

```

```

n, h, w = masks_tr.shape

```

```

masks_tr _reshaped = masks_tr.reshape(-1,1)

```

```

masks_tr _reshaped_encoded = labelencoder.fit_transform(masks_tr
_reshaped)

```

```

masks_tr _encoded_original_shape = masks_tr
_reshaped_encoded.reshape(n, h, w)

```

```

np.unique(masks_tr _encoded_original_shape)

```

```

masks_tr _input = np.expand_dims(masks_tr _encoded_original_shape,
axis=3)

```

```

from sklearn.model_selection import train_test_split

```

```

X1, X_test, y1, y_test = train_test_split(train_images, train_masks_input,
test_size = 0.3, random_state = 0)

```

```

X_train, X_do_not_use, y_train, y_do_not_use = train_test_split(X1, y1,
test_size = 0.3, random_state = 0)

```

```

print("Class values in the dataset are ... ", np.unique(y_train)) # 0 is the
background/few unlabeled

```

```

from keras.utils import to_categorical

```

```

masks_tr _cat = to_categorical(y_train, num_classes=n_classes)

```

```

y_train_cat = masks_tr _cat.reshape((y_train.shape[0], y_train.shape[1],
y_train.shape[2], n_classes))

masks_test_cat = to_categorical(y_test, num_classes=n_classes)
y_test_cat = masks_test _cat.reshape((y_test.shape[0], y_test.shape[1],
y_test.shape[2], n_classes))

n_classes=2
activation='softmax'
#activation='softplus'
LR = 0.0001
optim = keras.optimizers.Adam(LR)

dice_loss = sm.losses.DiceLoss(class_weights=np.array([0.5, 0.5]))
focal_loss = sm.losses.CategoricalFocalLoss()
total_loss = dice_loss + (1 * focal_loss)
metrics = [sm.metrics.FScore()]
BACKBONE1 = 'resnet34'
preprocess_input1 = sm.get_preprocessing(BACKBONE1)
X_train1 = preprocess_input1(X_train)
X_test1 = preprocess_input1(X_test)
model1 = sm.Unet(BACKBONE1, encoder_weights='imagenet',
classes=n_classes, activation=activation)
model1.compile(optimizer='adam', loss='categorical_crossentropy',
metrics=metrics)
print(model1.summary())

start1 = datetime.now()
history1=model1.fit(X_train1, y_train_cat, batch_size=5,
epochs=100, verbose=1, validation_data=(X_test1, y_test_cat))

```

```

stop1 = datetime.now()
execution_unet = stop1-start1
print("Unet time: ", execution_unet)
model1.save('unet__100epochs.hdf5')
hist1_df = pd.DataFrame(history1.history)
hist1_csv_file = 'history_unet_100epochs.csv'
with open(hist1_csv_file, mode='w') as f:
    hist1_df.to_csv(f)
##результати Модель 1 Unet
loss = history1.history['loss']
val_loss = history1.history['val_loss']
epochs = range(1, len(loss) + 1)
plt.plot(epochs, loss, label='Training loss (Втрата навчання)', color =
'red')
plt.plot(epochs, val_loss, label='Validation loss (Втрати навчання)', color
= 'green')
plt.title('Training and validation loss (Втрати навчання та тестування)')
plt.xlabel('Epochs (Епохи)')
plt.ylabel('Loss (Втрати)')
plt.legend()
plt.show()
acc = history1.history['f1-score']
val_acc = history1.history['val_f1-score']
plt.plot(epochs, acc, color = 'red', label='Training F (Навчання F1)')
plt.plot(epochs, val_acc, color = 'green', label='Validation F1 (Тестування
F1)')
plt.title('Training and validation F1 (Тестування та навчання F1)')
plt.xlabel('Epochs (Епохи)')
plt.ylabel('F')
plt.legend()

```

```

plt.show()
#####Модель 2 линкнет
model2 = sm.Linknet(BACKBONE1, encoder_weights='imagenet',
classes=n_classes, activation=activation)
model2.compile(optim, total_loss, metrics=metrics)
print(model2.summary())
start2 = datetime.now()
history2=model2.fit(X_train1, y_train_cat, batch_size=5,
epochs=100, verbose=1, validation_data=(X_test1, y_test_cat))
stop2 = datetime.now()
execution_linknet = stop2-start2
print("Linknet time: ", execution_linknet)
model2.save('linknet_100epochs.hdf5')
loss = history2.history['loss']
val_loss = history2.history['val_loss']
epochs = range(1, len(loss) + 1)
hist2_df = pd.DataFrame(history2.history)
hist2_csv_file = 'history_linknet.csv'
with open(hist2_csv_file, mode='w') as f:
    hist2_df.to_csv(f)

plt.plot(epochs, loss, label='Training loss (Втрата навчання)', color =
'red')
plt.plot(epochs, val_loss, label='Validation loss (Втрати навчання)', color
= 'green')
plt.title('Training and validation loss (Втрати навчання та тестування)')
plt.xlabel('Epochs (Епохи)')
plt.ylabel('Loss (Втрати)')
plt.legend()

```

```

plt.show()
f1 = history2.history['f1-score']
val_f1 = history2.history['val_f1-score']
plt.plot(epochs, f1, color = 'red', label='Training F (Навчання F1)')
plt.plot(epochs, val_f1, color = 'green', label='Validation F1 (Тестування
F1)')
plt.title('Training and validation F1 (Тестування та навчання F1)')
plt.xlabel('Epochs (Епохи)')
plt.ylabel('F')
plt.legend()
plt.show()

from keras.models import load_model

model_unet = load_model('unet_100epochs.hdf5', compile=False)
model_linknet = load_model('linknet_100epochs.hdf5', compile=False)

##from keras.callbacks import Callback,ModelCheckpoint
##from keras.models import Sequential,load_model
##from keras.layers import Dense, Dropout
##from keras.wrappers.scikit_learn import KerasClassifier
##import keras.backend as K

##
##

##def get_f1(y_true, y_pred): #taken from old keras source code
## true_positives = K.sum(K.round(K.clip(y_true * y_pred, 0, 1)))
## print(true_positives)
## possible_positives = K.sum(K.round(K.clip(y_true, 0, 1)))
## print(possible_positives)
## predicted_positives = K.sum(K.round(K.clip(y_pred, 0, 1)))
## print(predicted_positives)
## precision = true_positives / (predicted_positives + K.epsilon())
## print(precision)

```

```

## recall = true_positives / (possible_positives + K.epsilon())
## print(recall)
## f1_val = 2*(precision*recall)/(precision+recall+K.epsilon())
## print(f1_val)
## return f1_val

##from sklearn.metrics import f1_score
##F1_unet = sklearn.metrics.f1_score(y_test[:, :, 0], y_pred_unet_argmax,
labels=None, pos_label=1, average='binary', sample_weight=None,
zero_division='warn')
##print("Mean F1 - Unet:", F1_unet)

import random
test_img_number = random.randint(0, len(X_test1)-1)
test_img = X_test1[test_img_number]
ground_truth=y_test[test_img_number]
test_img_input=np.expand_dims(test_img, 0)
test_img_input1 = preprocess_input1(test_img_input)

test_pr_unet = model_unet.predict(test_img_input1)
test_pr_unet = np.argmax(test_pred_unet, axis=3)[0, :, :]

test_pr_linknet = model_linknet.predict(test_img_input1)
test_pr_linknet = np.argmax(test_pred_linknet, axis=3)[0, :, :]

plt.subplot()
plt.title('Testing Image')
plt.axis('off')
plt.imshow(test_img[:, :, 0])
plt.show()

plt.subplot()

```

```
plt.title('Testing Label')
plt.imshow(ground_truth[:, :, 0])
plt.axis('off')
plt.show()
```

```
#plt.figure(figsize=(12, 6))
plt.subplot()
plt.title('Unet result')
plt.imshow(test_prediction_unet )
plt.axis('off')
plt.show()
```

```
plt.subplot()
plt.title('Linknet result')
plt.imshow(test_prediction_linknet)
plt.axis('off')
plt.show()
```