

МІНІСТЕРСТВО ОСВІТИ І НАУКИ УКРАЇНИ
Харківський національний університет радіоелектроніки
Факультет Комп'ютерних наук
Кафедра Програмної інженерії

КВАЛІФІКАЦІЙНА РОБОТА Пояснювальна записка

рівень вищої освіти другий (магістерський)
Дослідження моделей та методів визначення типів сільськогосподарських
культур за супутниковими знімками
(тема)

Виконав:

студент 2 курсу, групи ПЗм-20-1
Несмянович А.В
(прізвище, ініціали)

Спеціальність 121 – Інженерія програмного
забезпечення

Тип програми Освітньо-наукова

Керівник доц. Голян В.В.
(посада, прізвище, ініціали)

Допускається до захисту

Зав. кафедри

З.В. Дудар

2022

ХАРКІВСЬКИЙ НАЦІОНАЛЬНИЙ УНІВЕРСИТЕТ РАДІОЕЛЕКТРОНІКИ

Факультет Комп'ютерних наук
(повна назва)

Кафедра Програмної інженерії
(повна назва)

Рівень вищої освіти другий (магістерський)

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

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

Освітня програма Інженерія програмного забезпечення
(повна назва)

ЗАТВЕРДЖУЮ:

Зав. кафедри _____
(підпис)

« ____ » _____ 20 ____ р.

ЗАВДАННЯ

на кваліфікаційну роботу

студента Несмяновича Андрія Владиславовича

(прізвище, ім'я, по батькові)

1. Тема роботи: Дослідження моделей та методів визначення типів сільськогосподарських культур за супутниковими знімками.
затверджена наказом університету від «24» березня 2022 р. № 412 Ст
2. Термін подання роботи до екзаменаційної комісії «__» _____ 2022 р.
3. Вихідні дані до проекту:
середовище проектування PyCharm 2022, мова розробки Python, хмарні сервіси GCP, інструментарій для управління ізольованими Linux-контейнерами Docker.
4. Перелік питань, що потрібно опрацювати в роботі:
аналіз предметної галузі, виявлення проблем, постановка задачі, аналіз вихідних даних датасету, опис існуючих алгоритмів, вибір алгоритму, опис

програмної реалізації, експеримента та аналіз результатів, висновки, перелік джерел посилання.

КАЛЕНДАРНИЙ ПЛАН

№	Назва етапів роботи	Терміни виконання етапів роботи	Примітка
1	Аналіз предметної області	25.02.2022	виконано
2	Постановка задачі	10.03.2022	виконано
3	Проведення дослідження	01.04.2022	виконано
4	Підготовка пояснювальної записки	03.05.2022	виконано
5	Підготовка презентації та доповіді	06.05.2022	виконано
6	Попередній захист	10.05.2022	виконано
7	Перевірка на академічний плагіат	10.05.2022	виконано
8	Нормоконтроль	12.05.2022	виконано
9	Рецензування	13.05.2022	виконано
10	Знесення диплома в електронний архів	15.05.2022	виконано
11	Допуск до захисту у зав. кафедри	15.05.2022	виконано

Дата видачі завдання 17.01.2022 р.

Студент _____

Керівник _____ доцент Голян В.В.

РЕФЕРАТ / ABSTRACT

Пояснювальна записка містить: 70 с., 20 рис., 21 джерел, 4 табл., 3 дод.

СІЛЬСЬКЕ ГОСПОДАРСТВО, ТИП КУЛЬТУРИ, АВТОМАТИЗАЦІЯ, МАШИННЕ НАВЧАННЯ, ГЕОГРАФІЧНА КАРТА.

Об'єктом дослідження є моделі та методи визначення типів сільськогосподарських культур за супутниковими знімками.

Мета роботи – дослідити, проаналізувати та порівняти моделі та методи визначення типів сільськогосподарських культур за супутниковими знімками.

Методи розробки базуються на таких технологіях, як Python, Docker, Pytorch.

У результаті роботи виконано аналіз та порівняння моделей та методів визначення типів сільськогосподарських культур за супутниковими знімками. Експериментально виявлено доцільність кожного з них та запропоновано метод, який є найкращим при порівнянні метрик якості моделей.

AGRICULTURE, CROP TYPE, AUTOMATIZATION, MACHINE LEARNING, GEOGRAPHICAL MAP.

The object of research is models and methods for determining the types of crops from satellite images.

The aim of the work is to investigate, analyze and compare models and methods of determining the types of crops from satellite images.

Development methods are based on such technologies as Python, Docker, Pytorch.

As a result of the work, the research, analysis and comparison of models and methods of determining the types of agricultural crops on the basis of satellite images was performed. The feasibility of each of them was experimentally proven and one of the methods was proposed, based on the model quality metrics.

Я, Несмянович Андрій Владиславович, студент групи ІПЗм-20-1, здобувач вищої освіти на другому (магістерському) рівні, кафедра Програмної інженерії, заявляю: моя кваліфікаційна робота на тему «Дослідження моделей та методів визначення типів сільськогосподарських культур за супутниковими знімками», що буде представлена до ЕК для публічного захисту, виконана самостійно, в ній не містяться елементи плагіату і вона може бути опублікована в електронному архіві відкритого доступу EIArKhNURE. Всі запозичення з друкованих та електронних джерел мають відповідні посилання.

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

ЗМІСТ

Перелік умовних скорочень.....	8
Вступ.....	9
1 Аналіз предметної галузі.....	11
1.1 Загальний аналіз галузі.....	11
1.1.1 Діджиталізація сільського господарства.....	11
1.1.2 Різновиди джерел даних для аналізу сільськогосподарських полів.....	12
1.1.3 Використання машинного навчання для розвитку сільського господарства.....	16
1.2 Постановка задачі.....	18
2 Аналіз існуючих алгоритмів.....	20
2.1 Деревя рішень та випадкові ліси.....	20
2.2 Метод опорних векторів.....	23
2.3 Нейронні мережі.....	24
3 Опис програмної реалізації.....	30
3.1 Вибір мови програмування.....	30
3.2 Підготовка датасету.....	31
3.2.1 Дані класів сільськогосподарських полів.....	31
3.2.2 Обробка Sentinel-1 зображень.....	34
3.2.3 Обробка Sentinel-2 зображень.....	37
3.3 Моделювання.....	41
4 Експерименти та аналіз результатів.....	43
4.1 Вхідні дані.....	43
4.2 Метрика якості.....	44
4.3 Експерименти.....	46

4.3.1 Порівняння різних методів між собою в однакових умовах.....	46
4.3.2 Порівняння використання різних комбінацій супутників.....	47
4.3.3 Порівняння різних діапазонів дат.....	48
4.4 Аналіз результатів.....	49
Висновки.....	51
Перелік джерел посилання.....	53
Додаток А Перелік джерел посилання за науковими напрямками керівника та науковців кафедри програмної інженерії.....	56
Додаток Б Стаття.....	57
Додаток В Слайди презентації.....	58

ПЕРЕЛІК УМОВНИХ СКОРОЧЕНЬ

ESA	European Space Agency, міжурядова організація, що складається з 22 держав-членів, присвячена дослідженню космосу
SNAP	Sentinel Application Platform, загальна програмна платформа, яка підтримує місії Sentinel
DNN	Deep Neural Network, штучна нейронна мережа з декількома шарами між вхідним і вихідним шарами
CNN	Convolutional Neural Network, клас штучної нейронної мережі, який найчастіше використовується для аналізу візуальних зображень
БПЛА	Безпілотний літальний апарат
NDVI	Normalized Difference Vegetation Index, індекс, що описує різницю між видимим і ближнім інфрачервоним відбиттям рослинного покриву
NDMI	Normalized Difference Moisture Index, індекс, що є надійним індикатором водного стресу в посівах

ВСТУП

Сільське господарство є однією з найстаріших областей діяльності людства. За тисячоліття розвитку людства, сільське господарство пройшло дуже довгий шлях інноваційних покращень - від застосування простих інструментів з каменю до побудови сучасних комплексів та лабораторій з аналізу найкращих сортів культур та способів їх вирощування.

На жаль багато не у всіх країнах світу найсучасніші научні та технологічні методи застосовуються у сільському господарстві. Теж можна сказати й про Україну, яка є одним із лідером з експорту продукції аграрного сектору в країни Євросоюзу [1].

Сільське господарство в Україні є одним із головних економічних секторів країни, що обумовлюється величезною кількістю чорнозему, що знаходиться на території країни. Таким чином, додавання процесів, що напряду покращують результати сільського господарства - є одним із важливих питань, які можуть позитивно вплинути на економічний стан країни.

Коли ми говоримо про сільське господарство, то по більшій частині ми говоримо саме про, вирощування різних типів культур, таких як озима і яра пшениця, кукурудза, овес, гречка та рис. Спостереження за цими рослинами відбирає дуже багато часу та не є доцільним із введенням сучасних технологій, які надають можливість спостереження та аналізу полів без безпосереднього втручання людини. До таких технологій можна віднести комбінацію зображень полів у високому розрішенні, які можна отримати за допомогою дронів або супутникових знімків та нещодавній ріст у якості систем комп'ютерного зору основаних на глибинному навчанні. Загальновідомо, що Україна має багато переваг у розвитку сільського господарства, зокрема родючі ґрунти та вигідне розташування. Але наразі український агробізнес привертає увагу іноземних інвесторів і завдяки високому рівню високотехнологічних інновацій. Українські агротехнологічні компанії розробляють інноваційні рішення, спрямовані на

вдосконалення традиційних методів ведення сільського господарства та розвиток органічного виробництва.

Цифрові технології та інновації вже сильно змінюють спосіб ведення агробізнесу, виводячи його ефективність на новий рівень. Використання дронів, супутників або безпілотних літальних апаратів (БПЛА) у сільському господарстві розглядається як одна з найбільш перспективних інновацій у цій галузі через високу економічну доцільність. Використання БПЛА має різноманітне застосування, в тому числі для ефективного планування сільського господарства, посилення контролю на кожному етапі сільськогосподарського виробництва, а також хімічної обробки посівів тощо. БПЛА здатні надавати важливу інформацію в режимі реального часу, такі дані, які збираються протягом тривалого часу. -term, також можна використовувати для кращого динамічного розуміння кожного процесу. БПЛА оснащені спеціальними датчиками, які забезпечують виявлення забруднених посівів, цільове внесення добрив, точкове обприскування та зрошення. Всього за 3 години БПЛА здатний засіяти площу в 10 квадратних кілометрів. Інші застосування БПЛА включають спостереження за робітниками, сільськогосподарською технікою та худобою, охорону полів тощо. БПЛА, оснащені тепловізійними камерами, дозволяють здійснювати охорону та спостереження вночі.

Таким чином було вирішено дослідити методи та моделі розпізнавання типів сільськогосподарських культур за супутниковими знімками, основною метою якої було б використання супутникових знімків для знаходження полів та типів культур, що на них ростуть, на території та аналіз знайдених результатів.

1 АНАЛІЗ ПРЕДМЕТНОЇ ГАЛУЗІ

1.1 Загальний аналіз галузі

1.1.1 Діджиталізація сільського господарства

Коли ми говоримо про діджиталізацію, ми маємо на увазі переведення даних у цифровий формат. Наразі, Україна робить багато кроків у напрямку діджиталізації процесів, що напряду відносяться до щоденних активностей громадян, наприклад оплата рахунків, переведення лікарняних відомостей в онлайн, тощо. Тому наступним кроком є застосування схожих підходів до різноманітних галузь виробництва, зокрема у сільському господарстві.

Основними перевагами діджиталізації сільського господарства є побудова аналітичних систем та систем запобігання занепаду ефективності сільського господарства, створення прозорих і надійних ланцюжків постачання продуктів, завчасне реагування на нестабільний ринок і ціноутворення. Загалом діджиталізація сільського господарства надає важливі економічні та стратегічні переваги для галузі, але головними недоліками є нестача експертів та робітників, які були б готові працювати із такими системами та необхідність інвестування у такі системи.

Цифрова трансформація сільського господарства дозволить:

- підвищення економічних та екологічних показників, що дозволяє фермерам процвітати;
- екологічна стійкість, що допомагає сільському господарству стати більш зеленим;
- конкурентоспроможність індустрії цифрового постачання ЄС;
- покращення умов праці аграріїв;
- підвищення прозорості вздовж ланцюга поставок.

1.1.2 Різновиди джерел даних для аналізу сільськогосподарських полів

На даний момент, найбільш поширеними джерелами даних для аналізу сільськогосподарських полів є знімки отримані із дронів, літаків та супутників. У кожного із цих джерел є як свої недоліки, так і переваги про які і піде річ далі.

Найбільшими компаніями, що займаються аналізом сільськогосподарської діяльності за допомогою знімків з дронів є 3DR, DroneDeploy, Pix4D та AgEagle [2]. Основними напрямками застосування знімків з дронів у даних компаніях є надання самих знімків та аналітики з використанням цих знімків. Прикладами аналітики, яку можна отримати з таких знімків високої роздільної здатності є рекомендаційні карти для поливу полів, моніторингу стану здоров'я полів та передбачення кількості врожаю, що буде отримано з певних ділянок полів. У порівнянні з іншими джерелами даних, знімки з дронів є найбільш детальнішими у сенсі того, яку кількість інформації можна з них отримати, але головним їх недоліком є важкість та ціна покриття великих областей такими високоякісними знімками. Задача аналізу великих областей є не лише великою логістичною проблемою для знімків із дронів, але й вимагає великих витрат для збору та збереження цих самих знімків.

Найбільшими компаніями, що займаються аналізом сільськогосподарської діяльності за допомогою знімків з дронів є Planet Labs, Google Maps Platform, та Mapbox [4]. Головною перевагою аерофотозйомок є їхня здатність надавати вид сільськогосподарських полів з висоти пташиного польоту. Одне зображення надає доступ до багатих даних про врожаї. На відміну від знімків із дронів, аерофотозйомка надає можливість збору багатоспектральних зображень, що дозволяють більш глибокого аналізу стану сільськогосподарських полів. Доволі частим застосуванням багатоспектральних зображень є обчислення “індексів”, які на пряму відображають стан поля. Прикладами таких індексів є NDVI (Нормалізований диференційний вегетаційний індекс) або NDMI (Нормалізований

індекс різниці вологості) (див. рис. 1.1). Використання таких індексів надає можливість більш легкої інтерпретації багатоспектральних знімків.




Рис. 1.1 – Приклад індексу NDVI [3]

Не зважаючи на те що, аерофотозйомка здається доволі підходящим джерелом для отримання знімків сільськогосподарських полів, останнє джерело даних є найкращим вибором – супутникові знімки. Основною причиною для цього є доступність та регулярність того, наскільки легко та часто можна отримати ці знімки.

Найбільшими постачальниками супутникових знімків на сьогоднішній момент являються наступні компанії: Planet Labs, DigitalGlobe (Maxar) and ESA (European Space Agency) [4].

Основною перевагою для супутникових знімків є те наскільки вони варіативні у сенсі роздільної здатності – роздільна здатність може відрізнятись від 1м на 1 піксель до 250м на 1 піксель, кількості каналів різної частоти, наявності компаній, що надають супутникові зображення безкоштовно та більш регулярного покриття територій інтересу.

Одним із найбільш поширених видом супутникових зображень для наукової діяльності є зображення отримані із сімейства супутників під назвою Sentinel, а саме зображення із супутників категорії Sentinel-1 та Sentinel-2. Зображення з обох супутників можуть бути із відкритих хмарних сховищ, таких як AWS або GCP.

Якщо супутникові зображення отримані з супутників Sentinel-2 (Sentinel-2A та Sentinel-2B) являються оптичні зображення – це тип зображення на яких сигнал здобувається за допомогою оптичних сенсорів, то зображення отримані з супутників Sentinel-1 є результатом роботи радару із синтетичною апертурою (SAR). SAR використовується для створення двовимірних зображень або тривимірних реконструкцій об'єктів, наприклад ландшафтів. SAR використовує рух радіолокаційної антени над цільовою областю, щоб забезпечити більш достатню просторову роздільну здатність, ніж звичайні радари зі скануванням променя. Приклад зображення отриманого за допомогою SAR можна побачити нижче на рис. 1.2.

Радар із синтетичною апертурою (SAR) є ефективним і важливим методом моніторингу посівів та інших сільськогосподарських об'єктів, оскільки його якість не залежить від погодних умов. SAR чутливий до геометричних структур і діелектричних властивостей цілей і має певну здатність до проникнення до деяких сільськогосподарських цілей. Можливості SAR для застосування в сільському господарстві можна розділити на три основні категорії: ідентифікація культур і статистика площі посіву сільськогосподарських культур, вилучення параметрів посівів і посівних земель та оцінка врожайності.




Рис. 1.2 – Приклад зображення отриманого за допомогою SAR [5]

Таким чином комбінація оптичних та радарних супутникових зображень може надати інформацію про те, що відбувається на поверхні Землі незалежно від наявності хмар, які часто заважають виконувати якісний аналіз того, що відбувається на поверхні Землі, через те, що оптичні зображення в такому випадку лише надають інформацію про наявність хмар, а не про те, що відбувається під ними.

Дані одного типу датчика часто не можуть дати однозначних відповідей, навіть за допомогою дуже ефективних алгоритмів, і навіть якщо проблема чітко визначена та обмежена за обсягом. Об'єднання інформації, що міститься в різних датчиках і даних різних типів, є одним із можливих рішень, яке досліджували протягом кількох десятиліть. Ідея об'єднання даних передбачає дослідження

взаємодоповнюваності та синергії різних видів даних, щоб отримати більш надійну та корисну інформацію про області, що аналізуються.

1.1.3 Використання машинного навчання для розвитку сільського господарства

Машинне навчання на протягом останніх 20 років набирало все більше та більше популярності у різноманітних сферах діяльності людей. Сільське господарство не стало винятком.

Якщо ми говоримо про використання машинного навчання у сільському господарстві, то слід зазначити, що машинне навчання може бути застосовано практично на будь-якому етапі розвитку рослинності. Так наприклад ми можемо визначити три основних етапи розвитку рослинності, для яких машинне навчання може бути застосовано – період до збору врожаю, період під час збору врожаю та період після збору врожаю (див. рис. 1.3). Якщо говорити про період до збору врожаю, то моделі машинного навчання можуть використані для виявлення деяких екологічних проблем або аномалій, наприклад стан ґрунту, наявність хвороби на рослинах, стан поливу, необхідність обрізки дерев, тощо. В випадку саме періоду збору, машинне навчання може бути використано для визначення кількості, якості та типу культури, що буде зібрана. Після збору, машинне навчання може бути використано для більш детального аналізу саме врожаю – його якість та певні параметри, які можуть розділити врожай у різні групи (розмір, колір, тощо).

На сьогоднішній момент існують компанії, основним фокусом яких є дослідження того, як машинне навчання може бути використано для часткової або повної автоматизації процесів, що є частиною сільського господарства, так наприклад вже є проекти, які фокусуються на створенні розумних теплиць, де відбувається моніторинг стану рослин та контролювання параметрів теплиці для покращення врожаю.

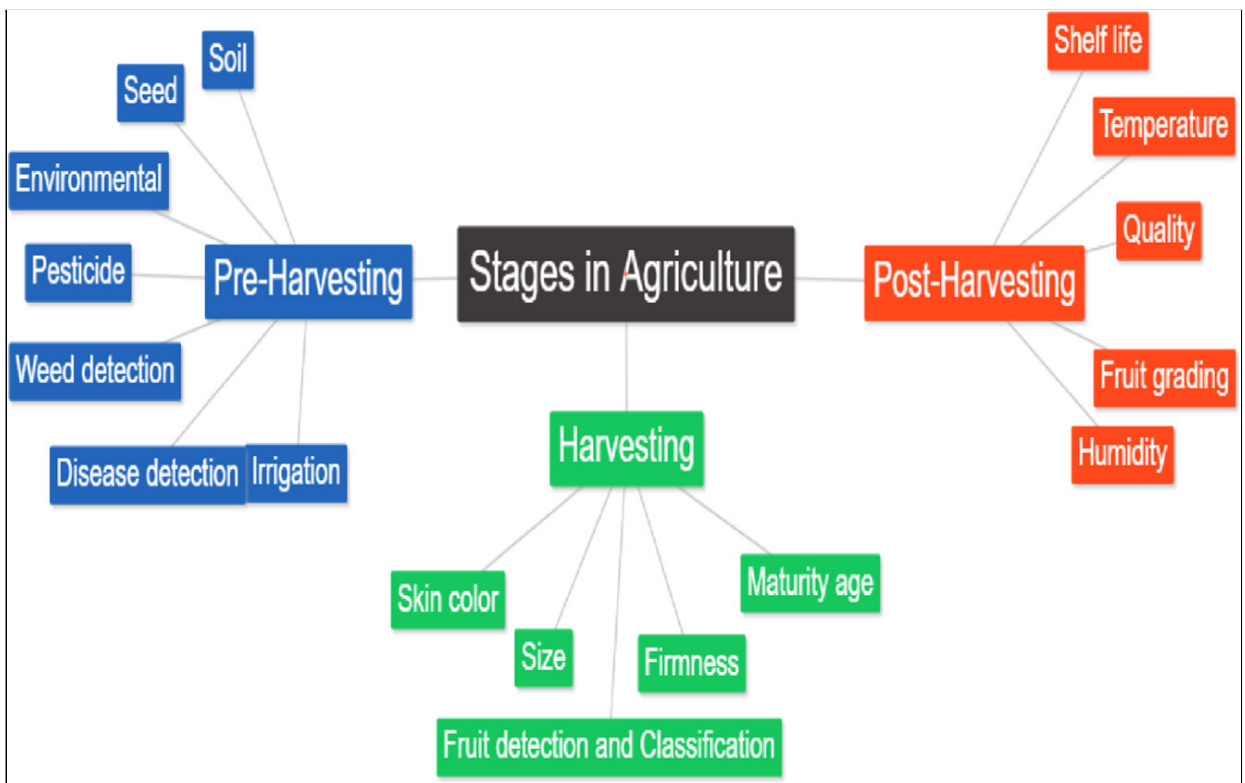


Рис. 1.3 – Приклади областей сільського господарства для застосування машинного навчання

Основною перевагою використання машинного навчання у сільському господарстві є можливість часткової або повної автоматизації процесів, що раніше виконувались людьми мануально. Такий підхід є досить дорого затратним при первинній розробці продукту, але може призвести до повної автоматизації певних галузей сільського господарства та покращення якості сільського господарства в цілому.

Розвиток у сфері машинного навчання допоміг покращити досягнення в сільському господарстві. Машинне навчання – це сучасна технологія, яка допомагає фермерам мінімізувати втрати у сільському господарстві, надаючи багаті рекомендації та уявлення про сільськогосподарські культури [6].

1.2 Постановка задачі

Після аналізу предметної області можна назвати основне завдання дослідження. Необхідно дослідити методи та моделі для визначення типів сільськогосподарських культур за супутниковими знімками.

Завдання визначення типів сільськогосподарських культур зводиться до задачі сегментації, де на вхід до моделі/методу подається зображення сільськогосподарського поля, а на вихід отримати зображення, де кожен піксель буде відноситись до певного класу, який буде позначити одну із сільськогосподарських культур.

Для реалізації мети на основі проведеного аналізу предметної області можна чітко сформулювати етапи виконання роботи:

- збір, перед обробка та аналіз даних;
- дослідити та обрати декілька підходів для вирішення задачі сегментації сільськогосподарських культур;
- розробити і порівняти обрані підходи на тестових даних, проаналізувати результати роботи різних підходів.

Перша стадія буде полягати із знаходження розмічених даних для задачі сегментації сільськогосподарських культур, завантаження даних та їх аналіз.

Після обробки розмічених даних, необхідно буде завантажити супутникові зображення за той же період, провести первинну обробку цих даних та їх аналіз.

Наступним кроком буде дослідження щодо існуючих підходів вирішення задачі сегментації, а також які особливості можуть при вирішенні задач пов'язаних із супутниковими знімками та задач в області сільського господарства.

Останнім кроком буде розробка та перевірка роботи знайдених підходів, методів і моделей для вирішення задачі сегментації сільськогосподарських культур.

Таким чином, у цьому розділі було проаналізовано предметну область та поставлені задачі для дослідження.

2 АНАЛІЗ ІСНУЮЧИХ АЛГОРИТМІВ

2.1 Дерева рішень та випадкові ліси

Дерева рішень – сімейство алгоритмів в основу яких полягає принцип побудови дерева, де кожен вузол дерева буде відповідати до деякого “рішення”, а саме вирішувати до якої частини дерева об’єкт, який досліджується буде відноситись [7]. Існують багато різновидів дерев, які розрізняються задачами які вони вирішують – регресія або класифікація, тим як саме будується дерево, а також такими параметрами як функція отримання інформації, обрізання дерева, кількість розділень в вузла (див. рис. 2.1).

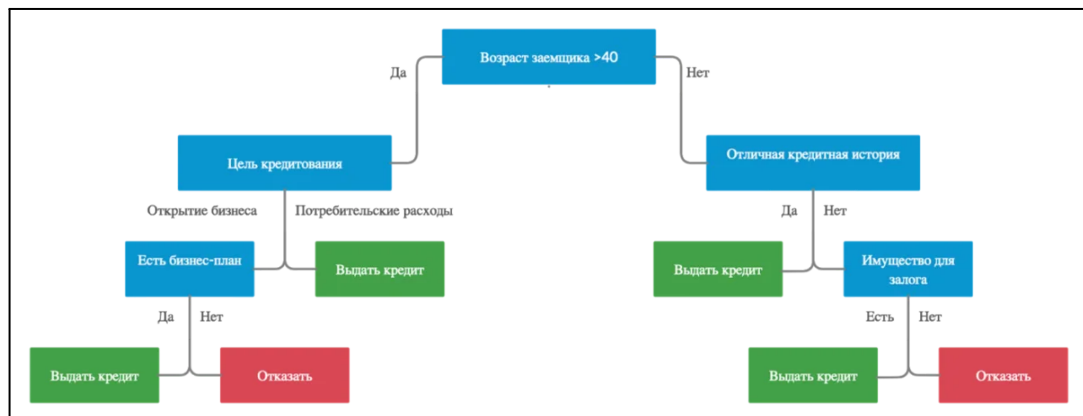


Рис. 2.1 – Приклад використання дерева рішень

Методи ансамблевої класифікації — це алгоритми навчання, які створюють набір класифікаторів замість одного класифікатора (див. рис. 2.2), а потім класифікують нові точки даних шляхом голосування за їхні прогнози. Останні класифікатори ансамблю: bagging, boosting та random forest. В алгоритмі bagging багато вибірок беруться з навчального набору даних із заміною для вивчення класифікатора, і для кожної вибірки створюється дерево, так що наступні дерева будуються незалежно від попередніх дерев, і для прогнозування береться проста більшість голосів. З іншого боку, підвищення використовує ітераційне перенавчання, і вага неправильно класифікованих вибірок збільшується в міру

проходження ітерацій, щоб зробити їх більш важливими в наступних ітераціях. Підвищення зазвичай зменшує як дисперсію, так і упередження класифікації, і в більшості випадків це значно точніше, ніж мішок; однак він має деякі недоліки. Він повільний, може потренуватися і чутливий до шуму.

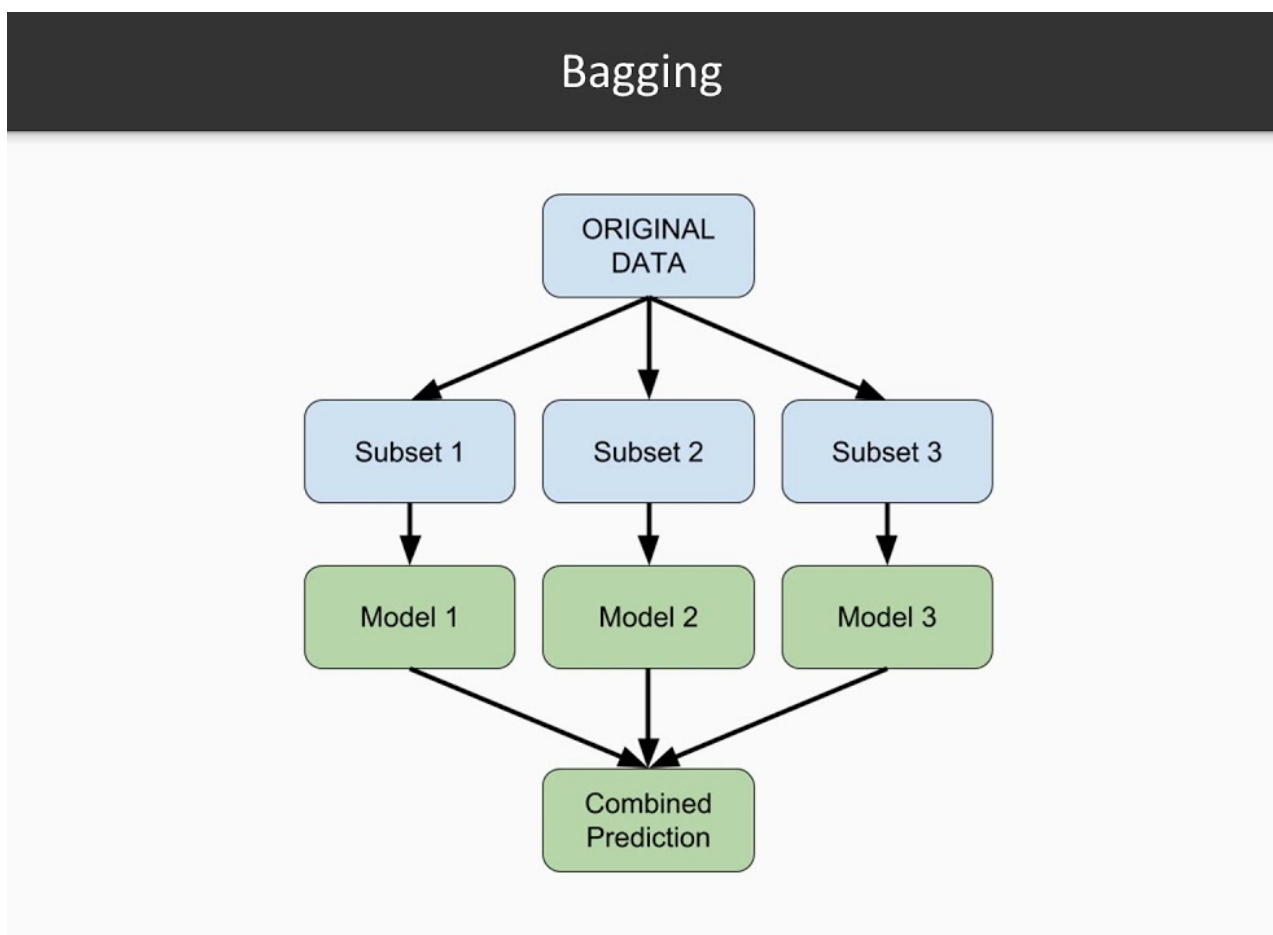


Рис. 2.2 – Приклад ансамблевої класифікації

Випадковий ліс можна описати як набір деревоподібних класифікаторів (див. рис. 2.3). Це розширена версія bagging, до якої додається випадковість. Замість того, щоб розбивати кожен вузол, використовуючи найкращий розподіл серед усіх змінних, випадковий ліс розбиває кожен вузол, використовуючи найкращий серед підмножини предикторів, випадково вибраних у цьому вузлі. Новий набір навчальних даних створюється з вихідного набору даних із заміною.

Потім дерево вирощується за допомогою випадкового вибору ознак. Вирослі дерева не обрізають.

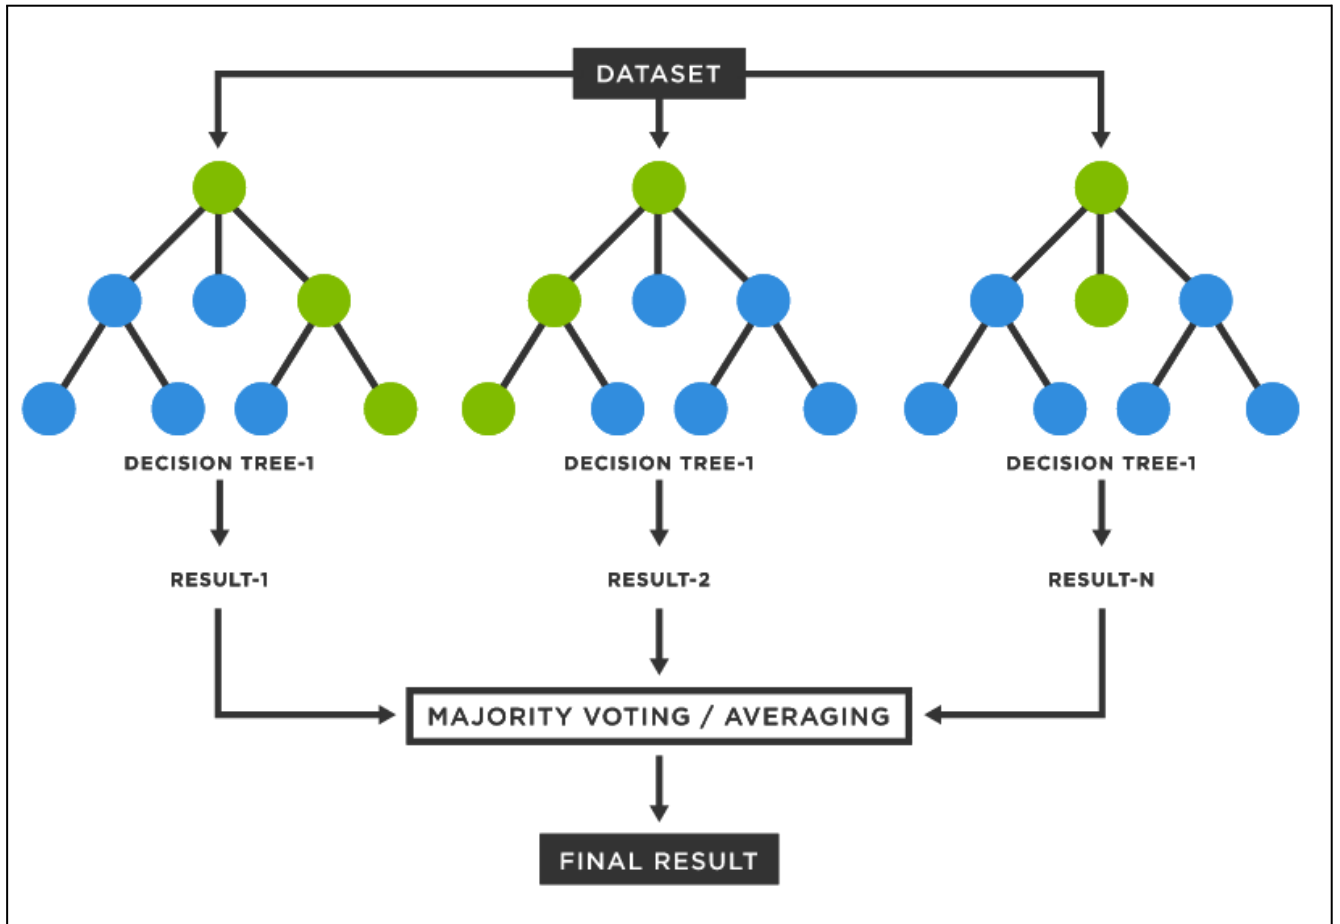


Рис. 2.3 – Приклад випадкового лісу

Ця стратегія робить випадковий ліс неперевершеною точністю в порівнянні з іншими існуючими алгоритмами, включаючи дискримінантний аналіз, машини опорних векторів і нейронні мережі. Випадковий ліс також дуже швидкий, він стійкий до перенавчання, і є можливість створення стільки дерев, скільки потрібно.

2.2 Метод опорних векторів

Машини опорних векторів (SVM) були вперше введені в роботу з основ теорії статистичного навчання. SVM по суті є двійковим класифікатором (див. рис. 2.4), який створює лінійну розділову гіперплощину для класифікації екземплярів даних [8]. Можливості класифікації традиційних SVM можуть бути істотно розширені шляхом перетворення вихідного простору ознак у простір особливостей більшого виміру за допомогою «трюка ядра». SVM використовувалися для класифікації, регресії та кластеризації. На основі глобальної оптимізації SVM вирішують проблеми переобладнання, які з'являються у просторах високої розмірності, що робить їх привабливими в різних програмах. Найчастіше використовувані алгоритми SVM включають регресію опорного вектора, машину опорних векторів найменших квадратів та машину послідовних алгоритмів проєкції з опорними векторами.




Рис. 2.4 – Приклад SVM для задачі бінарної класифікації

2.3 Нейронні мережі

Штучні нейронні мережі (ШНМ) поділяються на дві категорії; «Традиційні ANN» та «Глибокі ANN» (DNN) [9].

ШНМ створені завдяки функціональності людського мозку, імітуючи складні функції, такі як генерація шаблонів, пізнання, навчання та прийняття рішень. Мозок людини складається з мільярдів нейронів, які взаємодіють і обробляють будь-яку надану інформацію. Аналогічно, ШНМ як спрощена модель структури біологічної нейронної мережі складається із взаємопов'язаних процесорних блоків, організованих у певній топології. Кілька вузлів розташовано в кілька шарів, включаючи такі:

- вхідний рівень, на який дані подаються в систему,
- один або кілька прихованих шарів, де відбувається навчання
- вихідний рівень, на якому дається рішення/прогноз.

ШНМ – це контрольовані моделі, які зазвичай використовуються для задач регресії та класифікації. Алгоритми навчання, які зазвичай використовуються в ANN, включають мережі радіальних базисних функцій, алгоритми персептрона, зворотне поширення та стійке зворотне поширення. Крім того, повідомляється про велику кількість алгоритмів навчання на основі ANN, таких як алгоритми зустрічного поширення, адаптивно-нейросистеми нечіткого висновку, автоенкодер, XY-Fusion та контрольовані мережі Кохонена, а також як мережі Хопфілда, багат шаровий персептрон, самоорганізуючі карти, машини екстремального навчання, нейронна мережа узагальненої регресії, ансамблеві нейронні мережі або усереднення по ансамблю та самоадаптивне еволюційне екстремальне навчання машини.

DNN найчастіше називають глибоким навчанням (DL) або глибокими нейронними мережами (DNN) (див. рис. 2.5). Вони є відносно новою сферою досліджень ML, що дозволяє обчислювальним моделям, які складаються з кількох

рівнів обробки, вивчати складні представлення даних з використанням кількох рівнів абстракції. Однією з основних переваг DL є те, що в деяких випадках етап вилучення ознак виконує сама модель. Моделі DL суттєво покращили сучасний стан у багатьох різних секторах і галузях, включаючи сільське господарство. DNN — це просто ШМО з кількома прихованими шарами між вхідним і вихідним рівнями, і їх можна контролювати, частково або навіть не контролювати.




Рис. 2.5 – Приклад нейронної мережі

Поширеною моделлю DL є згорткова нейронна мережа (CNN), де карти ознак витягуються шляхом виконання згорток у області зображення. Інші типові архітектури DL включають глибоку машину Больцмана, мережу глибоких переконань та автоенкодер.

Згорткова нейронна мережа (CNN) — це алгоритм глибокого навчання, який може приймати вхідне зображення, призначати важливість (засвоювані ваги та

упередження) різним аспектам/об'єктам зображення та мати можливість відрізнити один від іншого (див. рис. 2.6). Попередня обробка, необхідна в CNN, набагато нижча в порівнянні з іншими алгоритмами класифікації. Хоча в примітивних методах фільтри створюються вручну, при достатньому підготовці CNN має можливість вивчати ці фільтри/характеристики.

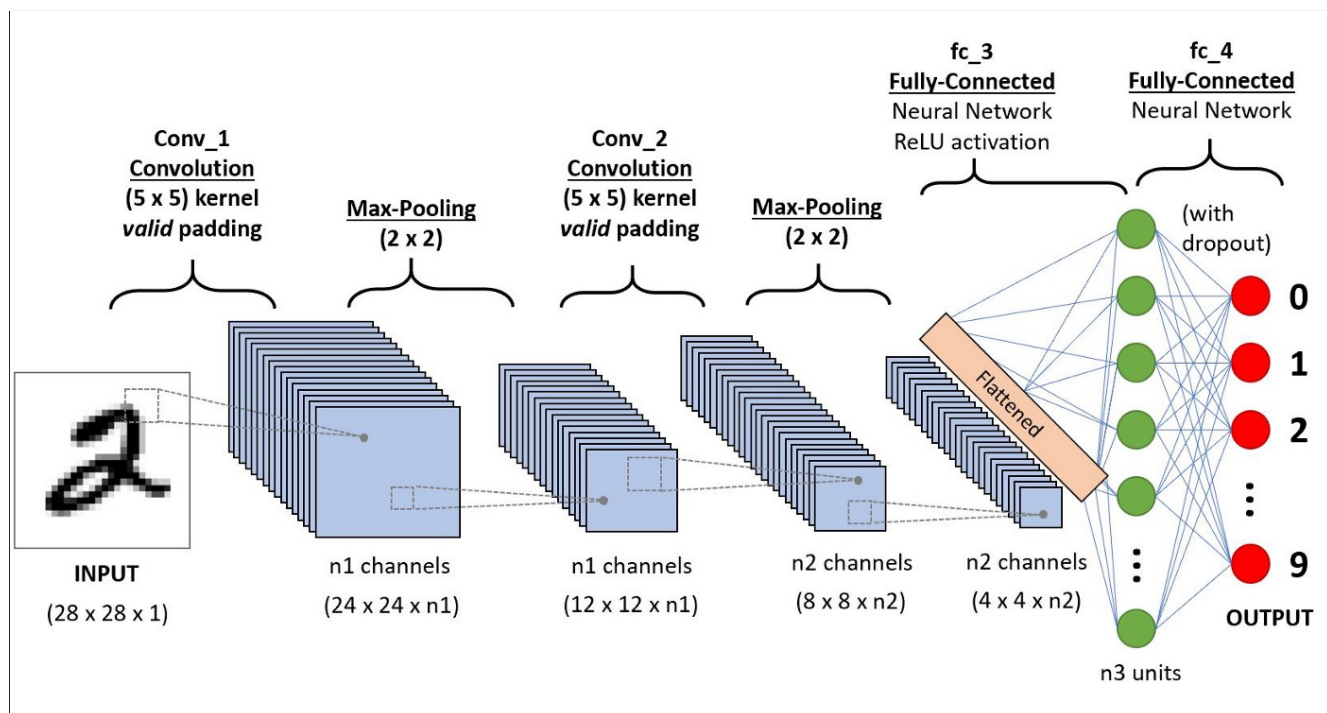


Рис. 2.6 – Приклад CNN для вирішення задачі класифікації

CNN може успішно фіксувати просторові та часові залежності в зображенні за допомогою застосування відповідних фільтрів. Архітектура краще відповідає набору даних зображення завдяки зменшенню кількості задіяних параметрів і можливості повторного використання ваг. Іншими словами, мережу можна навчити краще розуміти витонченість зображення.

UNet – це різновид архітектури нейронної мережі, де основа ідея архітектури полягає в тому, що вона складається з двох частин [10]. Перша частина мережі називається енкодер та її задача полягає в отриманнях деяких представлень з зображення, що подається на вхід енкодеру. Друга частина моделі називається декодер, та її основною задачею є саме отримання кінцевого

результату сегментації з представлень, які були отримані з енкодера. Особливість саме архітектури Unet полягає в тому, що крім енкодера та декодера архітектура також є так названі skip connection, які передають значення з різних рівнів енкодера до відповідних рівнів у декодері (див. рис. 2.7).

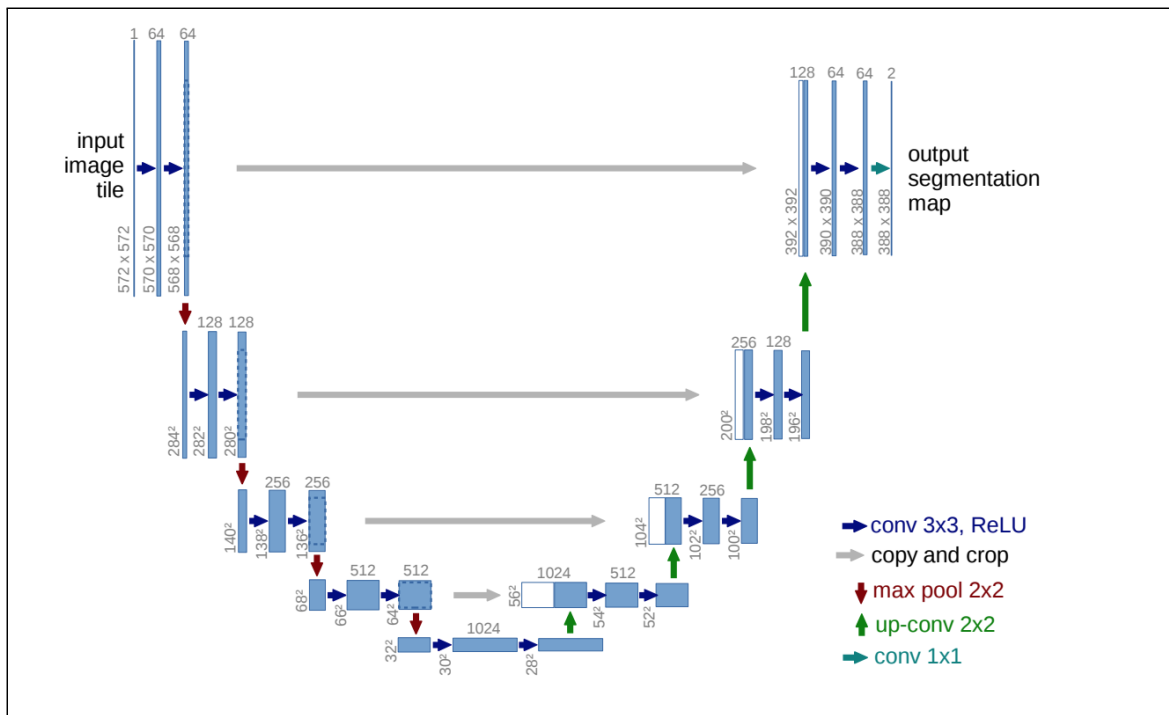


Рис. 2.7 – Приклад початкової версії архітектури UNet

LSTM – це архітектура рекурентних нейронних мереж. Основною ідеєю цієї моделі є те, що вона працює зазвичай із послідовністю, а не із одним об'єктом, що в нашому разі може бути послідовність пікселів, замість цілого зображення. Модель має деякий стан, який змінюється по мірі того, як входи передаються по самій мережі (див. рис. 2.8).




Рис. 2.8 – Архітектура нейронної мережі LSTM

В нашому випадку використання такої моделі має сенс тому, що дозволяє використовувати не лише інформацію за один день, але й об'єднати темпоральну інформацію за місяці розвитку культур.

Одним із недоліків цієї моделі буде те, що вона не оптимізована під вирішення задач сегментації і буде доволі повільно виконувати обчислення порівняно із UNet.

UNet-LSTM – це остання архітектура, яка буде розглянута. Її основною ідеєю є поєднання архітектур UNet та LSTM, а саме в основі моделі все ще полягає сегментаційна модель UNet, але коли модель видає фінальні результати масок для кожного з зображень, ці маски передаються далі до LSTM моделі, яка конвертує послідовність масок до однієї фінальної сегментаційної маски. Приклад роботи UNet-LSTM наведено нижче на рис. 2.9.

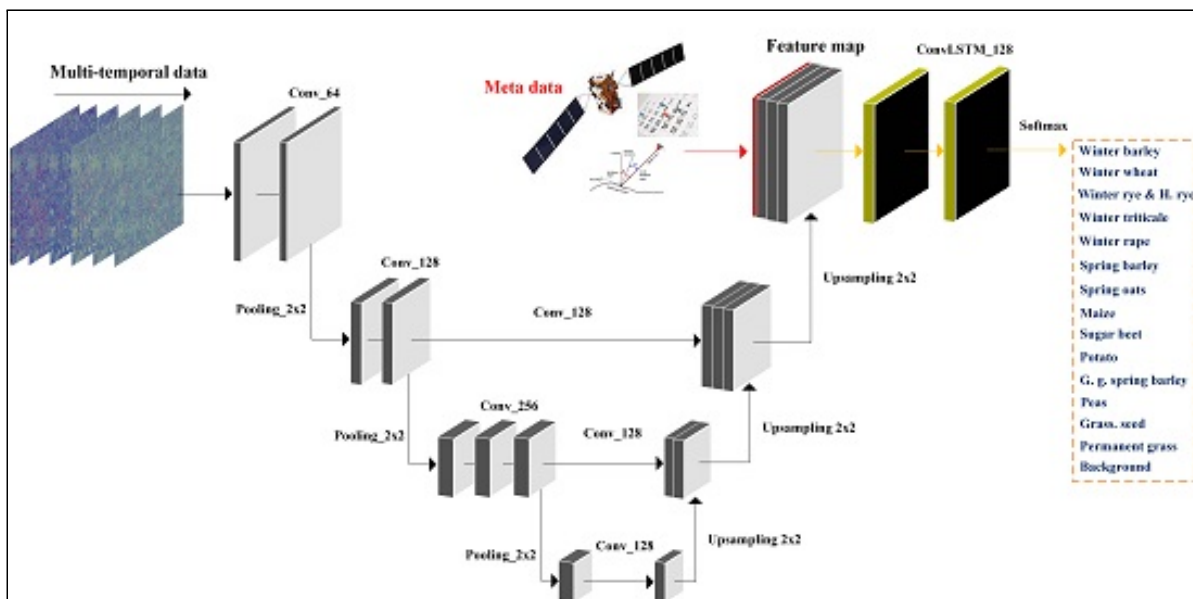


Рис. 2.9 – Приклад роботи UNet-LSTM

Основною перевагою даної моделі є те, що вона об'єднує переваги згорткових нейронних мереж, а саме їх можливість обробляти інформацію зображень із контекстом того, що відбувається навколо кожного пікселя та переваги рекурентних нейронних мереж, які надають можливість обробляти послідовності даних та надають моделі можливість отримувати інформацію у концепті часу.

Таким чином було розглянуто алгоритми дерева рішень та методу опорних векторів, а також алгоритми засновані на різних різновидах нейронних мереж. У наступному розділі, дані підходи будуть порівняні при вирішенні задачі визначення типів сільськогосподарських культур за супутниковими знімками.

3 ОПИС ПРОГРАМНОЇ РЕАЛІЗАЦІЇ

3.1 Вибір мови програмування

Python — інтерпретована об'єктно-орієнтована мова програмування високого рівня зі строгою динамічною типізацією [11]. Основними перевагами даної мови є великий лист вбудованих класів та модулів, що значно пришвидшують розробку рішень та легкість встановлення зовнішніх бібліотек за відсутності певної функціональності, наприклад модулі для обробки супутникових зображень.

В якості мови програмування була вище описана мова Python. Завдяки даному вибору розробка системи була швидкою, а код вийшов компактним і відмінно читаним. Базисом для вибору Python стала його насиченість бібліотеками для обробки різних типів даних та бібліотеками для машинного навчання. У якості IDE був обраний PyCharm, оскільки він повністю задовольняє мої потреби як розробника і є найкращим в своїй сфері.

Docker — інструментарій для управління ізольованими Linux-контейнерами. Для можливості повної повторності експериментів та результатів обробки даних весь розроблений код було розгорнуто у Docker контейнерах. Таким чином за необхідністю можна було розгорнути повне середовище розробки за введенням декількох команд.

Потрібно виділити основні бібліотеки, які були використані для обробки, аналізу даних та навчання моделі.

Shapely, geopandas, pyroSAR та rasterio – ці бібліотеки було використано для обробки растрів із супутниковими знімками та географічними даними. А саме shapely являється бібліотекою для взаємодії із геометриями. Geopandas – це модифікація бібліотеки Pandas, яка крім можливостей, що є в Pandas для обробки та аналізу даних, надає можливості аналізу векторних даних у географічних координатах. Бібліотеку pyroSAR було використано для передобробки

спутникових зображень Sentinel-1, а rasterio було використано для подальшого зчитування та модифікації згенерованих растрів.

Бібліотеки NumPy та pandas було використано для маніпуляції та зчитування табличних даних та масивів даних.

PyTorch — відкрита бібліотека машинного навчання на основі бібліотеки Torch, що використовують для таких застосувань, як комп'ютерне бачення та обробка природної мови [12]. PyTorch стала основою для побудови архітектури нейронної мережі, їх навчання та тестування. Для навчання моделей випадкового лісу та методу опорних векторів було використано бібліотеку SciPy, яка є бібліотекою Python з відкритим кодом та використовується для наукових обчислень і технічних обчислень.

3.2 Підготовка датасету

3.2.1 Дані класів сільськогосподарських полів

В якості даних з класами сільськогосподарських полів було обрано дані з відкритого ресурсу під назвою CropScape[13]. CropScape, розроблена в рамках Національної служби сільськогосподарської статистики США (NASS), є веб-інтерактивною системою візуалізації, розповсюдження та запитів для посівних угідь США. Дана система надає можливість завантаження растрів із більш ніж сотнею класів, включаючи типи культур, що було посіяно (див. рис. 3.1). Роздільна спроможність таких растрів становить 30 метрів на 1 піксель.

Для дослідження було обрано дані за 2019 та 2020 років. Було обрано дані за два урожайні сезони для того, щоб можна було отримати результати на тестових даних за наступний рік відносно того, на якому було виконано навчання моделей. Дані за 2019 рік були використані при навчанні, а дані за 2020, як тестові.

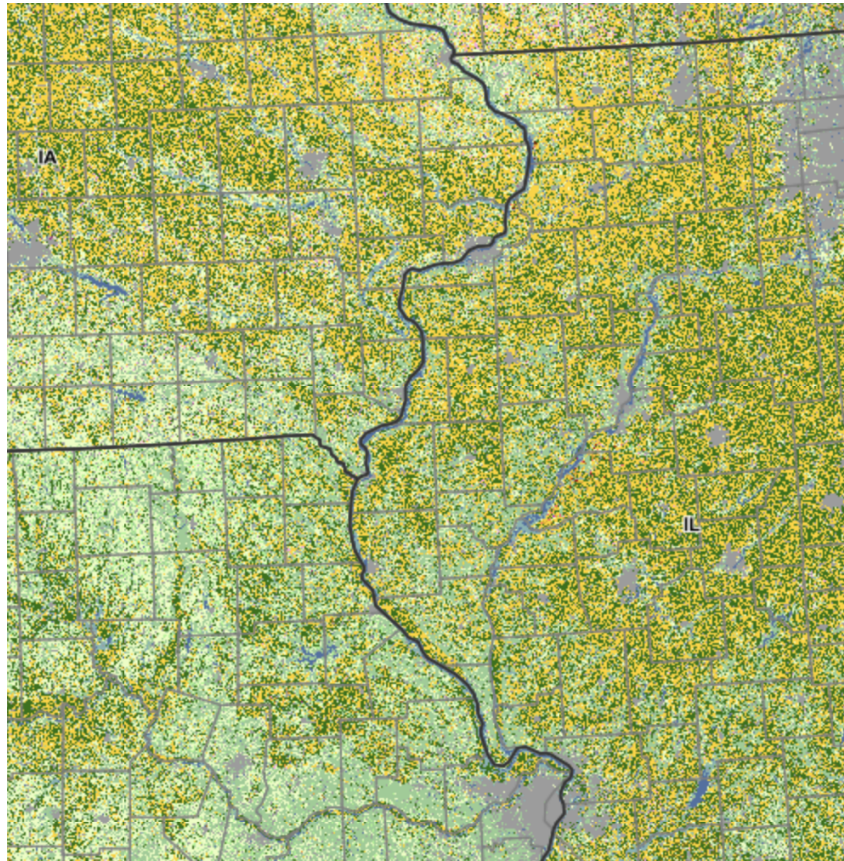


Рис. 3.1 – Приклад мапи взятої з CropScape. На даній мапі позначені типи сільськогосподарських культур

Наступним кроком після завантаження даних є аналіз даних. Нижче на рис. 3.2 наведено графіки розподілу класів сільськогосподарських культур та загальних класів зображуючих те, що відбувається на місцевості. Так можна побачити, що найбільш розповсюдженими з сільськогосподарських культур є кукурудза та соя, а серед інших це ліс, чагарники, пасовища, болота та городська місцевість. Виходячи за такого розподілення класів було вирішено обрати топ-10 класів за частотою та використовувати лише їх, як класи при навчання моделей.

Оскільки CropScape надає дані лише за штатами США, було вирішено обрати один із штатів, як головний об'єкт дослідження - таким об'єктом став штат Огайо. Штат Огайо є одним із найбільших агрокультурних регіонів США [14].




Рис. 3.2 – Розподілення класів в датасеті

Останнім кроком в передобробці було нарізання растрів на зображення меншого розміру 192X192 пікселі із метою подальшого цих зображень при навчанні моделей (див. рис. 3.3).




Рис. 3.3 – Приклад розрізання штату Огайо на зображення меншого розміру

3.2.2 Обробка Sentinel-1 зображень

Основною проблемою в використанні Sentinel-1 зображень є те, що в своєму початковому стані досить шумними та мають певні географічні спотворення, тобто координатна прив'язка пікселів досить часто не відповідає дійсним координатам значень. Причиною цього є саме природа Sentinel-1 зображень: зображення з супутників Sentinel-1 отримуються за рахунок зйомки “збоку”, а не “зверху”, як це зроблено в Sentinel-2. Наглядно це можна побачити на схемі, що наведено на рис. 3.4 нижче.




Рис. 3.4 – Зліва наведено приклад зйомки “зверху”, справа приклад зйомки “збоку”

Саме тому першими кроками при обробці знімків Sentinel-1 є видалення таких спотворень та шумів.

Для обробки Sentinel-1 знімків було використано ESA SNAP (Sentinel Application Platform). SNAP є спільною архітектурою для всіх Sentinel Toolbox, які в свою чергу використовуються для обробки знімків з відповідних супутників, наприклад Sentinel-1 Toolbox для знімків Sentinel-1. Однією із частин ESA SNAP додатку є інструмент з назвою Graph Processing Tool (GPT), який представляє собою інтерфейс командного рядка для запуску пайплайнів побудованих із SNAP операторів.

При обробці Sentinel-1 зображень було використано наступні операції (в лапках наведено назви SNAP операторів)[15]:

- apply orbit file (Apply-Orbit-File);
- thermal noise removal (ThermalNoiseRemoval);
- border noise removal (Remove-GRD-Border-Noise);
- calibration (Calibration-Sigma);
- speckle filtering (Speckle-Filter);
- range doppler terrain correction (Terrain-Correction);

— conversion to dB (LinearToFromdB).

Нижче наведено Python код для обробки Sentinel-1 зображень, де виконуються декілька викликів GPT утиліти та зберігаються результати обробки:

```
def preprocess_sentinel1_tile(src_file: str, dst_file: str, dst_crs:
str):
    tmp_dir = os.path.abspath(os.path.join(os.path.dirname(dst_file),
"tmp"))

    src_file = os.path.abspath(src_file)
    tmp_tif_path = os.path.join(tmp_dir, tmp_tif)
    tmp_warped_tif_path = os.path.join(tmp_dir, "tmp_warped.tif")
    tmp_scaled_tif_path = os.path.join(tmp_dir, "tmp_scaled.tif")
    tmp_dim_path = os.path.join(tmp_dir, tmp_dim)
    tmp_xml_path = os.path.join(tmp_dir, tmp_xml)
    os.makedirs(tmp_dir, exist_ok=True)
    change_read_write_nodes(raw_to_beamdimap_xml_path, tmp_xml_path,
src_file, tmp_dim_path)
    gpt(tmp_xml_path, removeS1BorderNoiseMethod=None, cleanup=False,
        gpt_args=[f"-Presolution={resolution}",
            f"-Porigin={origin}",
            f"-Pfilter={filter}",
            f"-Pdem={dem}",
            f'-Pinput={src_file}',
            f'-Poutput={tmp_dim_path}',
            '-J-Xmx8G'])
    change_read_write_nodes(dim_to_geotiff_xml_path, tmp_xml_path,
tmp_dim_path, tmp_tif_path)
    gpt(tmp_xml_path,
        removeS1BorderNoiseMethod='ESA',
        cleanup=False,
        gpt_args=[
            f'-Pinput={tmp_dim_path}',
            f'-Poutput={tmp_tif_path}',
            '-J-Xmx8G'])
```

Лістинг 3.1 – Код обробки Sentinel-1 зображень

```

gdal.Warp(tmp_warped_tif_path, tmp_tif_path, srcSRS="EPSG:4326",
dstSRS=dst_crs, dstNodata=0.0)
scale_sentinel1_raster(tmp_warped_tif_path, tmp_scaled_tif_path)
os.rename(tmp_scaled_tif_path, dst_file)
shutil.rmtree(tmp_dir)

```

Продовження лістингу 3.1

3.2.3 Обробка Sentinel-2 зображень

Супутникові зображення Sentinel-2 надають мультиспектральні дані в 13 діапазонах: видимому, близькому інфрачервоному, і інфрачервоному короткохвильовому спектра. З цих 13 діапазонів було обрано 10, а саме:

- синій;
- зелений;
- червоний;
- ближній інфрачервоний (NIR);
- чотири спекти червоного краю;
- два короткохвильові інфрачервоні (SWIR).

Також було розраховано два додаткові індекси на основі обраних мультиспектральних даних - нормалізований диференційний вегетаційний індекс (NDVI) та нормалізований диференційний індекс вологості (NDMI). Індекси NDVI та NDMI розраховуються за формулами (1) та (2) відповідно.

$$NDVI = \frac{NIR - Red}{NIR + Red}, \quad (1)$$

де NIR – ближній інфрачервоний канал, Red – червоний канал.

$$NDMI = \frac{NIR - SWIR}{NIR + SWIR}, \quad (2)$$

де SWIR – ближній інфрачервоний канал, Red – короткохвильовий інфрачервоний канал.

Відповідно до формули 3.1, щільність рослинності (NDVI) в певній точці зображення дорівнює різниці інтенсивностей відбитого світла в червоному та інфрачервоному діапазоні, поділений на суму цих інтенсивностей. Нижче на рис. 3.5. наведено приклад того, як може змінюватись NDVI в залежності від об'єкту, для якого він розріховується.




Рис 3.5 – Приклад значень NDVI в залежності від здоров'я об'єкту спостережень

Цей індекс має значення від -1,0 до 1,0, де негативні значення в основному утворюються з хмар, води і снігу, а значення, близькі до нуля, в основному утворюються з каменів і голого ґрунту. Дуже малі значення (0,1 або менше) функції NDVI відповідають порожнім ділянкам каменів, піску або снігу. Помірні значення (від 0,2 до 0,3) означають чагарники та луки, а великі значення (від 0,6 до 0,8) вказують на помірні та тропічні ліси. EOS Crop Monitoring успішно використовує цю шкалу, щоб показати фермерам, які частини їхніх полів мають густу, помірну або рідку рослинність у будь-який момент.

Простіше кажучи, NDVI — це показник стану здоров'я рослин, заснований на тому, як рослина відбиває світло на певних частотах (одні хвилі поглинаються, а інші відбиваються).

NDMI виявляє рівні вологості в рослинності за допомогою комбінації ближнього інфрачервоного (NIR) і короткохвильового інфрачервоного (SWIR) спектральних діапазонів. Це надійний індикатор нестачі води в посівах.

Сильні умови посухи не тільки загрожують посівам, а й можуть знищити весь урожай. NDMI може виявити водний стрес на ранній стадії, ще до того, як проблема вийшла з-під контролю. Крім того, використання NDMI для моніторингу зрошення, особливо в районах, де сільськогосподарським культурам потрібно більше води, ніж може забезпечити природа, допомагає значно покращити ріст врожаю. Все це робить NDMI відмінним інструментом для ферми. А оскільки сухі умови в зонах, схильних до пожежі, підвищують ризик горіння, NDMI має ще одне застосування: моніторинг рівня палива.

Значення індексу NDMI можуть бути приблизно інтерпретовані за даними наданими у таблиці 3.1 нижче.

Таблиця 3.1 Значення NDMI та його інтерпретація

Значення	Інтерпретація значення індексу
-1 – -0,8	Голий ґрунт
-0,8 – -0,6	Майже відсутнє покриття зеленню
-0,6 – -0,4	Дуже низьке покриття зеленню
-0,4 – -0,2	Низький навіс, сухий або дуже низький покрив, вологий.
-0,2 – 0	Середньо-низьке покриття навісу, висока водна напруга низьке навантаження на воду
0 – 0,2	Середнє покриття зеленню та високий водний стрес та низький водний стрес

Кінець таблиці 3.1

0,2 – 0,4	Середньо-високе покриття зеленню та високий водний стрес або середнє покриття зеленню та низький водний стрес
0,4 – 0,6	Високе покриття зеленню, відсутність водного стресу
0,6 – 0,8	Дуже високе покриття зеленню, відсутність водного стресу
0,8 – 1	Повне покриття зеленню, відсутність водного стресу/перезволення

Нижче наведено реалізацію розрахунку індексів NDVI та NDMI:

```
def create_ndvi(self):
    self.create_index(input1_band="B04", input2_band="B08",
    calc="(B-A)/(A+B+0.001)", index_name="NDVI")
def create_ndmi(self):
    self.create_index(input1_band="B11", input2_band="B8A",
    calc="(B-A)/(A+B+0.001)", index_name="NDMI")
def create_index(self, input1_band, input2_band, calc, index_name):
    start_time = time.time()
    logger.info(f'Creating {index_name} band for {self.tile_index}
    started')
    input1_file_path = self.get_band_file_path(self.tmp_tile_folder,
    input1_band, ext=self.output_ext)
    input2_file_path = self.get_band_file_path(self.tmp_tile_folder,
    input2_band, ext=self.output_ext)
    output_file_path =
    self.get_band_file_path(self.tmp_tile_folder, index_name,
    ext=self.output_ext)
    if not os.path.exists(output_file_path):
        calculate_index(input1_file_path, input2_file_path,
    output_file_path, calc)
    logger.info(f'Took {time.time() - start_time} seconds for creating
    {index_name} band for {self.tile_index}')
    logger.info(f'Creating {index_name} band for {self.tile_index}
    finished')
def calculate_index(input1, input2, outfile, calc="(B-A)/(A+B+0.001)":
    try:
        Calc(calc,
            str(outfile),
            A=str(input1),
            B=str(input2),
            NoDataValue=None,
            type='Float32',
            format=None,
            creation_options=None,
```

Лістинг 3.2 – Код обчислення NDVI та NDMI

```

        allBands='',
        overwrite=True,
        debug=False,
        quiet=True,
    )
except (IOError, ValueError, Exception):
    logger.error(f'Error when creating ndvi band for {outfile}\n\n',
exc info=True)

```

Продовження лістингу 3.2

3.3 Моделювання

Необхідно реалізувати основний код нейронної мережі, для цього використовуємо мову програмування Python. Наведемо приклад реалізації Unet-LSTM моделі із використанням бібліотеки Pytorch.

```

class UNetLSTM(nn.Module):
    def __init__(self, in_channel, n_classes, timesteps, dropout):
        super(UNet3D, self).__init__()
        self.in_channel = in_channel
        self.n_classes = n_classes
        feats = 16
        self.en3 = conv_block(in_channel, feats * 4, feats * 4)
        self.pool_3 = nn.MaxPool3d(kernel_size=2, stride=2, padding=0)
        self.en4 = conv_block(feats * 4, feats * 8, feats * 8)
        self.pool_4 = nn.MaxPool3d(kernel_size=2, stride=2, padding=0)
        self.center_in = center_in(feats * 8, feats * 16)
        self.center_out = center_out(feats * 16, feats * 8)
        self.dc4 = conv_block(feats * 16, feats * 8, feats * 8)
        self.trans3 = up_conv_block(feats * 8, feats * 4)
        self.dc3 = conv_block(feats * 8, feats * 4, feats * 2)
        self.final = nn.Conv3d(feats * 2, n_classes, kernel_size=3,
stride=1, padding=1)
        self.fn = nn.Linear(timesteps, 1)
        self.logsoftmax = nn.LogSoftmax(dim=1)
        self.dropout = nn.Dropout(p=dropout, inplace=True)

    def forward(self, x):
        x = x.cuda()
        en3 = self.en3(x)
        pool_3 = self.pool_3(en3)
        en4 = self.en4(pool_3)
        pool_4 = self.pool_4(en4)
        center_in = self.center_in(pool_4)
        center_out = self.center_out(center_in)

```

Лістинг 3.3 – Імплементация нейронної мережі на мові програмування Python.

```
concat4 = torch.cat([center_out, en4], dim=1)
dc4 = self.dc4(concat4)
trans3 = self.trans3(dc4)
concat3 = torch.cat([trans3, en3], dim=1)
dc3 = self.dc3(concat3)
final = self.fn(dc3)
final = final.permute(0, 1, 3, 4, 2)

shape_num = final.shape[0:4]
final = final.reshape(-1, final.shape[4])
final = self.dropout(final)
final = self.fn(final)
final = final.reshape(shape_num)
final = self.logsoftmax(final)

return final
```

Продовження лістингу 3.3

Таким чином було реалізовано код для перед обробки даних для тренувального та тестового датасетів, та побудовано архітектуру нейронної мережі.

4 ЕКСПЕРИМЕНТИ ТА АНАЛІЗ РЕЗУЛЬТАТІВ

4.1 Вхідні дані

Як було описано в попередньому розділі, загалом було використано десять смуг від Sentinel-2, а також дві додаткові індексні смуги та два діапазони від Sentinel-1. Ці смуги використовувалися під час експериментів, і не проводились експерименти з їх підмножинами. Зображення мали розмір 192x192 пікселі, і під час навчання до них були застосовані деякі основні доповнення, такі як обрізання, перевертання, повороти та зміна розміру. Приклад того що є доповнення зображення наведено нижче на рисунку 4.1.

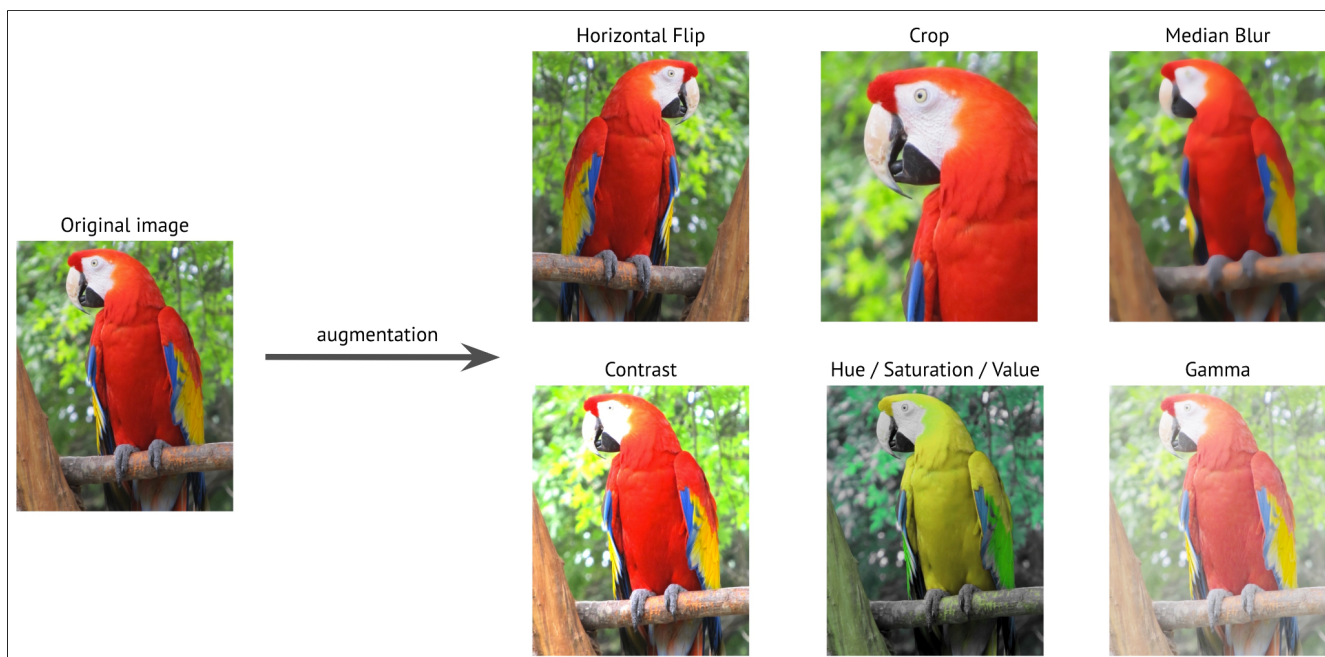


Рис. 4.1 – Приклад доповнення зображення

Для уникнення перенавчання, навчальну вибірку було поділено на три набори: тренувальний, валідаційний та тестовий. Розділ навчальної вибірки Train-Valid-Test — це метод оцінки ефективності вашої моделі машинного навчання — як класифікації, так і регресії. Ви берете заданий набір даних і

поділити його на три підмножини. Нижче наведено короткий опис ролі кожного з цих наборів даних.

Тренувальний набір даних — це набір даних, що використовуються для навчання (за моделлю), тобто для зміни параметрів моделі машинного навчання.

Валідаційний набір даних — це набір даних, що використовується для забезпечення неупередженої оцінки моделі, встановленої на наборі тренувальних даних, під час налаштування гіперпараметрів моделі. Валідаційний набір також відіграє роль в інших формах підготовки моделі, таких як вибір ознак, вибір порогового відсікання.

Тестовий набір даних — це набір даних, що використовується для забезпечення неупередженої оцінки остаточної моделі, встановленої на наборі навчальних даних.

Набір даних був розділений на набори для тренування, валідації та тестування із співвідношенням 70/20/10 відповідно.

Було реалізовано стратегію вибірки при навчання на групах часових послідовностей зображень - дана реалізація надала можливість тренувати моделі не дивлячись на те, що часові послідовності зображень відрізняються в залежності від ділянки землі для якої проводиться аналіз.

4.2 Метрика якості

В статистичному аналізі бінарної класифікації, F-міра — це одна з мір точності тесту. Її обчислюють через влучність та повноту тесту, де влучність є числом правильно визначених позитивних результатів, поділеним на число всіх позитивних результатів, включно з визначеними неправильно, а повнота є числом правильно визначених позитивних результатів, поділеним на число всіх зразків, які повинно було бути визначено як позитивні.

Міра F_1 є середнім гармонійним цих влучності та повноти (3). Найвищим можливим значенням F -міри є 1, що вказує на ідеальні влучність та повноту, а найнижчим можливим значенням є 0, якщо або влучність, або повнота є нульовими. Міра F_1 є також відомою як індекс Соренсена, та коефіцієнт подібності Дайса.

$$F_1 = \frac{2}{\text{recall}^{-1} + \text{precision}^{-1}}, \quad (3)$$

де precision – влучність, recall – повнота.

Для задачі класифікації кількох класів міра F_1 не обчислюється як загальна. Замість цього міра F_1 обчислюється для кожного класу за принципом «один проти відпочинку». У цьому підході оцінюється успіх кожного класу окремо, ніби для кожного класу існують окремі класифікатори.

Для розрахунку міри F_1 декількох класів будується матриця невідповідностей. Матриця невідповідностей — це таблиця особливого компонування, що дає можливість унаочнювати продуктивність алгоритму, зазвичай керованого навчання. Кожен з рядків цієї матриці представляє зразки прогнозованого класу, тоді як кожен зі стовпців представляє зразки справжнього класу (див. рис. 4.2).

Саме міра F_1 буде використана у якості метрики якості при порівнянні експериментів між собою. Основними класами за якими буде вестися порівняння є класи сільськогосподарських культур, класи наземної інфраструктури, води та лісів, тощо. Основними класами сільськогосподарських культур, на яких буде зроблено фокус при порівнянні результатів експериментів є класи сої та кукурудзи.

		Predicted	
		0	1
Actual	0	30	12
	1	8	56

Рис 4.2 – Приклад матриці невідповідностей

4.3 Експерименти

4.3.1 Порівняння різних методів між собою в однакових умовах

Початкові умови в яких порівнюються методи є наступними:

- використання Sentinel-1 та Sentinel-2 зображень;
- використання даних за увесь діапазон дат.

Для використання випадкового лісу та методу опорних векторів було розраховано додаткові ознаки для кожного з пікселів зображення. Ці ознаки представляють собою статистичні величини часових послідовностей, такі як середнє значення, квантілі, стандартне відхилення, тощо. В результаті тренування на даних 2019 року та тестуванні на даних 2020 року було отримано значення метрик якості для класів показані в таблиці 4.1.

Таблиця 4.1 Порівняння різних методів між собою в однакових умовах

Модель	Міра F_1
Випадковий ліс	Кукурудза:0.7315 Соя:0.7543
Метод опорних векторів	Кукурудза: 0.5401 Соя:0.5973
Нейронні мережі (UNet-LSTM)	Кукурудза:0.8165 Соя:0.8306

Результатом даного експерименту можна вважати те, що якість роботи нейронних мереж переважає за випадковий ліс на 7-8% та 25-30 % за метод опорних векторів. Тому наступні експерименти з різних комбінацій супутників та різних часових проміжків були проведені виключно для нейронних мереж.

4.3.2 Порівняння використання різних комбінацій супутників

В даному експерименті було розглянуто, як вибір супутникових даних впливає на точність моделі (див. табл. 4.2).

Таблиця 4.2 Результати експерименту

Супутники	F1-score
Sentinel-1	Кукурудза:0.5431 Соя:0.5890

Кінець таблиці 4.2

Sentinel-2	Кукурудза:0.7847 Соя:0.8018
Sentinel-1 та Sentinel-2	Кукурудза:0.8165 Соя:0.8306

З результатів експерименту можна зробити наступні висновки:

- використання виключно Sentinel-2 зображень порівняно із Sentinel-1 дає сильно кращі результати у середньому перевищуючи 20%;
- додавання Sentinel-1 зображень до Sentinel-2 надає покращення в ~3%, що показує що Sentinel-1 все ж таки може бути використаний для надання додаткової інформації для моделі.

4.3.3 Порівняння різних діапазонів дат

В попередніх експериментах завжди було використано повний діапазон дат, а саме з початку квітня до кінця серпня. Ціллю цього експерименту є виявлення залежності точності моделлю від довжини та вибору початку та кінця місяців проміжку. Результати проведеного експерименту наведені в таблиці 4.3.

Таблиця 4.3 - Результати експерименту з порівняння різних проміжків дат

Проміжок часу	Міра F_1
Квітень-серпень (5 місяців)	Кукурудза: 0.8399 Соя: 0.8539

Кінець таблиці 4.3

Квітень-липень (4 місяці)	Кукурудза: 0.8224 Соя:0.8117
Травень-серпень (4 місяці)	Кукурудза: 0.8082 Соя: 0.8492
Квітень-червень (3 місяці)	Кукурудза: 0.5400 Соя:0.3927

Згідно з результатів експерименту можна зробити висновок, що скорочення проміжку часу, за який беруться дані призводить до зменшення точності моделі.

Також потрібно відмітити, що точність моделі різко зменшується на ~30% при використанні лише перших трьох місяців - таке поведінка напряду пов'язана з тим, що посадка обраних культур відбувається із кінця квітня до початку червня [16].

4.4 Аналіз результатів

Основними результатами експериментів можна вважати наступні тези:

- поєднання використання супутникових зображень Sentinel-1 та Sentinel-2 надає найкращі результати за метриками якості;
- використання п'яти місяців повного врожайного сезону надає найкращі результати за метриками якості;
- використання нейронних мереж надає найкращі результати за метриками якості.

Нижче на рисунку 4.3 зображено модель того, як саме було використано нейронну мережу UNet-LSTM для отримання мапи із класифікацією сільськогосподарських полів.

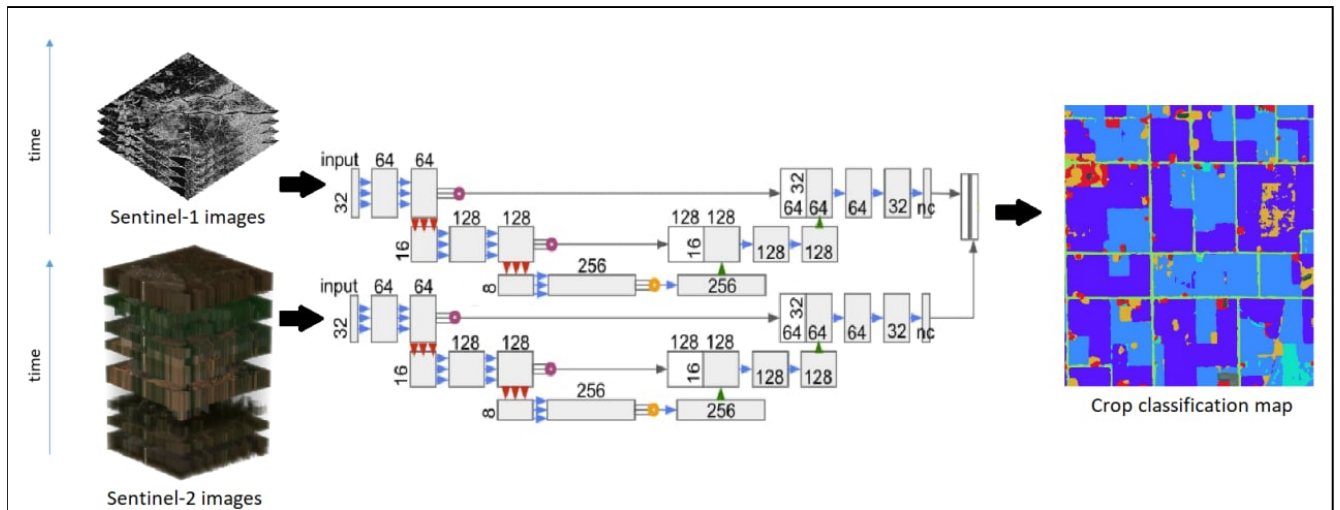


Рис. 4.3 - Візуалізація підходу

Було переглянуто результати інших досліджень [16][17] та в більшості випадків саме використання нейронних мереж надає найкращі результати при тому із великим відривом. Використання нейронних мереж в цілому має більший потенціал через те, що процес навчання цих моделей може бути уніфіковано в незалежно від кількості, а також ці моделі будуть лише покращуватись, якщо їм надати більшу кількість даних.

ВИСНОВКИ

В результаті роботи були досліджені методи та моделі визначення типів сільськогосподарських культур за супутниковими знімками.

Перш за все були проведені дослідження предметної області, а саме – сільського господарства, супутникових знімків та їх застосування для вирішення задач сільського господарства. В рамках етапу цього було виявлено основні джерела супутникових зображень, а також задачі які можуть бути вирішені із їх використанням.

Розробка велась з використанням мови програмування Python та таких бібліотек машинного навчання як: `pytorch`, `numpy` та `pandas`. Для роботи з географічними та растровими даними було застосовано `shapely`, `geopandas`, `pyroSAR` та `rasterio`.

Було проведено дослідження існуючих моделей машинного навчання, призначених для вирішення завдання сегментації. Серед розглянутих методів були наступні: випадковий ліс, метод опорних векторів та різні архітектури нейронних мереж.

Було збудовано архітектуру нейронної мережі та проведено її навчання з використанням побудованого датасету супутникових зображень.

На основі низки експериментів було проведено аналіз та порівняння впливання використання оптичних Sentinel-2 зображень та радарних Sentinel-1 зображень для вирішення задачі класифікації сільськогосподарських полів. Також було наведено порівняння того, як вибір періоду дат за які беруться дані впливає на точність натренованих моделей.

Натренована модель може бути використана для визначення типів сільськогосподарських культур за супутниковими знімками. Для створення оточення розробки була використана технологія Docker.

В подальшому на основі досліджених методів та моделей може бути розроблена програмна система, яка дасть можливість перегляду результатів моделі, а також відображення аналізу результатів отриманих моделлю, наприклад агрегація за певним регіоном або кількість тієї чи іншої культури в певному регіоні. Також планується покращення якості роботи моделлю за рахунок збільшення тренувального датасету та ансамблювання різних моделей.

ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ

1. DLF.UA Інформаційний сайт про сільське господарство в Україні.
Режим доступу до ресурсу: <https://dlf.ua/ua/silске-gospodarstvo-v-ukrayini/>
(дата звернення: 21.03.2022).
2. UAVCOACH.COM Top 100 Drone Companies in 2021 – Режим доступу до ресурсу: <https://uavcoach.com/drone-companies/> (дата звернення: 21.03.2022).
3. OPENWEATHER.MEDIUM.COM Visualization of the NDVI index on satellite maps. Custom palettes for agricultural applications – Режим доступу до ресурсу:
<https://openweathermap.medium.com/visualisation-of-the-ndvi-index-on-satellite-maps-custom-palettes-for-agricultural-applications-f99b0652f991> (дата звернення: 21.03.2022).
4. APPGEO.COM Top Satellite and Aerial Imagery Companies – Режим доступу до ресурсу:
<https://www.appgeo.com/top-satellite-and-aerial-imagery-companies/> (дата звернення: 21.03.2022).
5. SENTINELS.COPERNICUS.EU Sentinel-1. Maritime Monitoring – Режим доступу до ресурсу:
<https://sentinels.copernicus.eu/web/sentinel/user-guides/sentinel-1-sar/applications/maritime-monitoring> (дата звернення: 21.03.2022).
6. Vishal Meshram, Kailas Patil, Vidula Meshram, Dinesh Hanchate, S.D. Ramkteke. Machine learning in agriculture domain: A state-of-art survey, Artificial Intelligence in the Life Sciences, Volume 1 – 2021 – 11p.
7. Chris Smith, Mark Koning. Decision Trees and Random Forests: A Visual Introduction For Beginners – October 2017 – 168p.

8. Aurelien Geron. Hands-On Machine Learning with Scikit-Learn and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems 1st Edition- December 2017 – 572p.
9. Nikhil Buduma. Fundamentals of Deep Learning: Designing Next-Generation Machine Intelligence Algorithms 1st Edition – August 2017 – 298p.
10. Olaf Ronneberger, Philipp Fischer, Thomas Brox. U-Net: Convolutional Networks for Biomedical Image Segmentation – May 2015 – 20p.
11. David Beazley, Brian K. Jones. Python Cookbook: Recipes for Mastering Python 3 – June 2011 – 1392 p.
12. Eli Stevens, Luca Antiga, and Thomas Viehmann Foreword. Deep Learning with PyTorch – July 2020 – 520p.
13. NASSGEODATA.GMU.EDU CropScape – Cropland Data Layer – Режим доступу до ресурсу: <https://nassgeodata.gmu.edu/CropScape> (дата звернення: 1.05.2022).
14. USDA.GOV U.S. Department of agriculture <https://www.usda.gov/topics/research-and-science> (дата звернення: 1.05.2022).
15. Federico Filipponi. Sentinel-1 GRD preprocessing workflow – June 2019 – 5p.
16. IPAD.FAS.USDA.GOV U.S. Department of Agriculture. Crop Calendars for United States – Режим доступу до ресурсу: <https://ipad.fas.usda.gov/ogamaps/cropcalendar.aspx> (дата звернення: 29.04.2022).
17. Vittorio Mazzia, Aleem Khaliq, Marcello Chiaberge. Improvement in land cover and crop classification based on temporal features learning from Sentinel-2 data using recurrent-convolutional neural network (R-CNN) – May 2020 - 21p.
18. Charlotte Pelletier, Geoffrey I. Webb and François Petitjean. Temporal Convolutional Neural Network for the Classification of Satellite Image Time Series – February 2019 – 22p.

- 19.Голян В. В., Бітюкова Є. І. Дослідження технологій та інструментів управління проектами// Монографія: SCIENCE, RESEARCH, DEVELOPMENT#27/NECHNICS AND TECHNOLOGY – 2020. – 33 с.
- 20.Голян В. В., Кравченко О. К. Порівняння моделей життєвих циклів програмного забезпечення з метою виявлення найефективнішого// Збірник наукових праць ХНУ ІС № 2 (157) – 2019. – 6 с.
- 21.V. Apukhtin, M. Shirokopetleva, V. Skovorodnikova. The Relevance of Using Message Brokers in Robust Enterprise Applications// IEEE International Scientific-Practical Conference Problems of Infocommunications, Science and Technology (PICS&T), 2019. – P. 305-309.