

Міністерство освіти і науки України  
НАЦІОНАЛЬНИЙ УНІВЕРСИТЕТ «КИЄВО-МОГИЛЯНСЬКА  
АКАДЕМІЯ»

Факультет інформатики  
Кафедра мультимедійних систем

**Магістерська робота**

Освітній ступінь: магістр

**На тему: «ГІБРИДНА ЕКСПЕРТНА СИСТЕМА З  
ВИКОРИСТАННЯМ НЕЙРОННИХ МЕРЕЖ»**

Виконав студент 2 року навчання

Спеціальності

122 Комп'ютерні науки

Кундік Кирило Володимирович

Керівник

Афонін А.О.

кандидат фіз.-мат. наук

Рецензент

Магістерська робота захищена

з оцінкою \_\_\_\_\_

Секретар ЕК С.А. Мелещенко

«\_\_\_\_» \_\_\_\_\_ 2022

Київ 2022

Міністерство освіти і науки України  
НАЦІОНАЛЬНИЙ УНІВЕРСИТЕТ «КИЄВО-МОГИЛЯНСЬКА  
АКАДЕМІЯ»

Кафедра мультимедійних систем факультету інформатики

ЗАТВЕРДЖУЮ

Зав.кафедри мультимедійних систем,  
канд. фіз.-мат. наук, доцент

\_\_\_\_\_ О. П. Жежерун  
(підпис)

“ \_\_\_\_ ” \_\_\_\_\_ 202\_ р.

**ІНДИВІДУАЛЬНЕ ЗАВДАННЯ**

на магістерську роботу

студенту 2 р.н. магістерської програми Комп’ютерні науки Кундіку Кирилу  
Розробити Гібридну експертну систему з використанням нейронних мереж

Зміст текстової частини до магістерської роботи:

Зміст

Анотація

Вступ

Розділ 1. Аналіз предметної області

Розділ 2. Дослідження гібридних експертних систем та мереж  
навчених передавальним навчанням

Розділ 3. Опис практичної частини дослідження

Висновки

Список джерел

Додатки

Дата видачі “ \_\_\_\_ ” \_\_\_\_\_ 202\_ р.

Керівник \_\_\_\_\_ (підпис)

Завдання отримано \_\_\_\_\_ (підпис)

**Тема:** Гібридна експертна система з використанням нейронних мереж

### Календарний план виконання роботи:

| № п/п | Назва етапу дипломного проекту (роботи)                                                                                              | Термін виконання етапу | Примітка |
|-------|--------------------------------------------------------------------------------------------------------------------------------------|------------------------|----------|
| 1.    | Отримання завдання на дипломну роботу.                                                                                               | 02.11.2021             |          |
| 2.    | Огляд технічної літератури за темою роботи.                                                                                          | 15.11.2021             |          |
| 3.    | Виконати аналіз сучасних методів сегментації та передавального навчання.                                                             | 02.12.2021             |          |
| 4.    | Розробка гібридної експертної системи з використанням мережі сегментації та мережі передавального навчання.                          | 30.12.2021             |          |
| 5.    | Програмування розробленого алгоритму.                                                                                                | 01.02.2022             |          |
| 6.    | Застосування розробленого алгоритму для виявлення хвороби рослини за зображенням її ураженого листа.                                 | 15.02.2022             |          |
| 7.    | Виконання порівняльного аналізу результатів прогнозування, отриманих за допомогою розробленого алгоритму на основі нейронної мережі. | 01.05.2022             |          |
| 8.    | Написання пояснювальної роботи.                                                                                                      | 10.06.2022             |          |
| 9.    | Створення слайдів для доповіді та написання доповіді.                                                                                | 14.06.2022             |          |
| 10.   | Аналіз отриманих результатів з керівником, написання доповіді та попередній захист магістерської роботи.                             | 15.06.2022             |          |
| 11.   | Корегування роботи за результатами попереднього захисту.                                                                             | 29.06.2022             |          |
| 12.   | Остаточне оформлення пояснювальної роботи та слайдів                                                                                 | 30.06.2022             |          |
| 13.   | Захист магістерської роботи (проекту)                                                                                                | 06.07.2022             |          |

Студент \_\_\_\_\_ Кундік К.В. \_\_\_\_\_

Керівник Афонін А.О.

“ ” p.

## Зміст

|                                                                                                                              |           |
|------------------------------------------------------------------------------------------------------------------------------|-----------|
| <b>Анотація .....</b>                                                                                                        | <b>7</b>  |
| <b>Вступ .....</b>                                                                                                           | <b>8</b>  |
| <b>1 АНАЛІЗ ПРЕДМЕТНОЇ ОБЛАСТІ.....</b>                                                                                      | <b>11</b> |
| 1.1 Аналіз сучасного стану питання та обґрунтування теми .....                                                               | 11        |
| 1.2 Огляд існуючих лабораторних підходів для виявлення хвороби<br>рослин.....                                                | 12        |
| 1.2.1 Прямі методи виявлення .....                                                                                           | 12        |
| 1.2.2 Непрямі методи виявлення.....                                                                                          | 14        |
| 1.2.3 Висновок щодо аналізу лабораторних підходів.....                                                                       | 17        |
| 1.3 Огляд існуючих підходів з використанням експертних систем .....                                                          | 18        |
| 1.3.1 Класифікаційна мережа .....                                                                                            | 19        |
| 1.3.2 Мережа виявлення .....                                                                                                 | 22        |
| 1.3.3 Мережа сегментації.....                                                                                                | 25        |
| 1.3.4 Висновки щодо досліджених структур нейронних мереж.....                                                                | 28        |
| 1.4 План проведення наукового дослідження .....                                                                              | 30        |
| <b>2 ДОСЛІДЖЕННЯ СУЧАСНИХ ТЕХНОЛОГІЙ ЕКСПЕРТНИХ<br/>СИСТЕМ ТА ПЕРЕДАВАЛЬНОГО НАВЧАННЯ .....</b>                              | <b>31</b> |
| 2.1 Основні концепції гібридних експертних систем .....                                                                      | 31        |
| 2.2 Проблеми і завдання нейронних мереж.....                                                                                 | 33        |
| 2.3 Мережі сегментації, їх структура і застосування.....                                                                     | 35        |
| 2.4 Концепції передавального навчання .....                                                                                  | 39        |
| 2.5 Висновки до розділу .....                                                                                                | 42        |
| <b>3 ОПИС ПРАКТИЧНОЇ ЧАСТИНИ ДОСЛІДЖЕННЯ .....</b>                                                                           | <b>43</b> |
| 3.1 Розширення набору даних за допомогою лінійних трансформацій,<br>накладання оптичних ефектів, накладанням шкідників ..... | 43        |
| 3.2 Розробка сегментаційної моделі .....                                                                                     | 47        |
| 3.3 Навчання моделі із застосуванням передавального навчання.....                                                            | 50        |
| 3.4 Використання хмарного сервісу AWS для навчання.....                                                                      | 53        |
| 3.5 Результати дослідження та їх порівняння .....                                                                            | 56        |

|                                             |           |
|---------------------------------------------|-----------|
| <b>Висновки .....</b>                       | <b>60</b> |
| <b>Список Використаної Літератури .....</b> | <b>62</b> |
| <b>Додаток А .....</b>                      | <b>71</b> |
| <b>Додаток Б .....</b>                      | <b>72</b> |
| <b>Додаток В .....</b>                      | <b>73</b> |

### Перелік прийнятих скорочень

|       |                                                                                                         |
|-------|---------------------------------------------------------------------------------------------------------|
| ПЛР   | – полімеразна ланцюгова реакція;                                                                        |
| ДНК   | – дезоксирибонуклеїнова кислота;                                                                        |
| РНК   | – рибонуклеїнова кислота;                                                                               |
| ІФА   | – імуноферментний аналіз;                                                                               |
| CNN   | – згорткова нейронна мережа;                                                                            |
| VGG   | – архітектура згорткової нейронної мережі;                                                              |
| SVM   | – метод опорних векторів;                                                                               |
| ROI   | – регіон інтересів;                                                                                     |
| R-CNN | – згорткові нейронні мережі на основі регіонів;                                                         |
| SSD   | – одноетапний метод виявлення об'єктів;                                                                 |
| YOLO  | – «You only look once» метод розпізнавання об'єктів, що прогоняє зображення через мережу лише один раз; |
| FCN   | – нейронна мережа повної згортки;                                                                       |
| AWS   | – веб-сервіси компанії Amazon;                                                                          |
| CLI   | – інтерфейс командного рядка.                                                                           |

### Анотація

У роботі описано розроблену гібридну експертну систему з використанням нейронних мереж, що дає змогу розпізнавати хвороби рослин за зображенням їхнього листя. Модель має вищу точність в порівнянні з наявними розробками, швидкий час передбачення. Детально висвітлено проведення дослідження сучасних архітектур моделей сегментації та передавального навчання з акцентом на досягнення найвищої точності та найменшої помилки при вирішенні задачі класифікації зображень. Продемонстровано ефективність запропонованих рішень на прикладі створення гібридної експертної системи розпізнавання хворіб сільськогосподарських рослин.

**Ключові слова:** експертні системи, машинне навчання, класифікація зображень, сегментація зображень, комп'ютерний зір, передавальне навчання, глибинне навчання, хвороби сільськогосподарських рослин.

## Вступ

"Глобальна продовольча криза, на яку раніше вже вплинули пандемія COVID-19 та зміни клімату, призводить до високого рівня голоду в усьому світі ще й через війну в Україні та блокування експорту зерна", — про це заявили понад 75 доповідачів в Раді Безпеки ООН.

Україна забезпечує продовольством понад 400 мільйонів людей. Коли така кількість їжі стає недоступною, нестачу починають відчувати по всій території планети. Через це виробництво їжі, збір врожаїв і контроль за ними мають покращуватися, а вплив шкідників, вірусів — зменшуватися. Для досягнення таких цілей мають залучатися всі доступні методи, особливо новітні інформаційні засоби такі як: експертні системи, бази знань, машинне навчання та комп'ютерний зір.

Сьогодні малим та середнім підприємства агропромислового комплексу доводиться власноруч перевіряти ледь не кожную рослину власного врожаю. Процес такої ручної перевірки займає дуже велику кількість часу, тим більше, що звичайний людський фактор може вплинути на загальну врожайність та продукцію фермера через необережність, неуважність або банально через нестачу робочої сили.

Виходячи з тенденцій за мету даної роботи були поставлені розробка та реалізація нової гібридної експертної системи з використанням нейронних мереж для класифікації хвороби сільськогосподарських рослин.

Робота складається з трьох основних розділів.

Перший розділ присвячено аналізу існуючих методів комп'ютерного зору та лабораторних досліджень для виявлення хвороби рослин. Наведено детальний огляд моделей машинного навчання для ідентифікації хвороби рослин, розібрано переваги і недоліки таких методів. Визначено план проведення подальшого дослідження.



У другому розділі описані концепти експертних систем, нейронних мереж сегментації та передавального навчання. Описано теорію розробки гібридних експертних систем, проаналізовано створення архітектури нейронних мереж із застосування передавального навчання, розібрано кращі практики використання та застосування мереж сегментації.

Третій розділ містить детальний опис проведеного дослідження. Описано методи, які застосовувалися для розширення наявного набору даних із хворобами рослин. Представлено окремий модуль нейронної мережі для сегментації зображень листя рослин. Описано розробку архітектури основної класифікаційної мережі із застосуванням передавального навчання. Наведено результати та порівняння з іншими дослідженнями виявлення хвороби рослин із застосуванням технік комп'ютерного зору.

Застосування експертної системи з нейронними мережами має на меті автоматизувати процес перевірки сільськогосподарських рослин на різні хвороби. Це зменшить об'єм робіт для агрономів, скоротить вплив людського фактору під час перевірки якості вирощуваних рослин та підвищить загальну врожайність агропромислового комплексу. Така автоматизована система також може стати в нагоді як любителям садівничого процесу, так і аграріям великих агропідприємств для виявлення первинних ознак хвороби без залучення дорогих та довготривалих лабораторних тестувань.

Постановка задачі:

1. Дослідити існуючі методи і проблеми виявлення хвороби сільськогосподарських рослин.
2. Проаналізувати гібридні експертні системи, що використовують нейронні мережі. Дослідити сегментаційні та класифікаційні мережі, передавальний метод машинного навчання.

3. Розробити гібридну експертну систему, що має класифікувати хвороби рослин.
4. Виконати порівняльний аналіз використаних методів передбачення на тестових та реальних даних. Зробити висновки щодо можливостей покращення використаних методів.

## 1 АНАЛІЗ ПРЕДМЕТНОЇ ОБЛАСТІ

### 1.1 Аналіз сучасного стану питання та обґрунтування теми

Автоматизована діагностика хвороби рослин є одним з найактивніших напрямків досліджень у сільському господарстві. Своєчасне та точне виявлення хвороби рослин є важливим для забезпечення глобальної продовольчої безпеки та стійкості агропромислового комплексу більшості країн. Протягом останніх років машинне навчання зробило революцію в області комп'ютерного зору і тепер стає стандартним інструментом для багатьох додатків. Для підтримки фермерів і зниження втрат з точки зору продуктивності рослин було розроблено багато методів автоматизованої діагностики хвороби рослин на основі глибинного навчання та інших технологій.

Однак ці програми часто страждають від перенавчання, тому діагностична продуктивність в польових умовах різко знижується під час застосування передбачення на даних з нових середовищ. Причини перенавчання у всіх попередніх дослідженнях різні в залежності від використаних технологій машинного навчання. Тому ще не було розроблено сталу уніфіковану систему, яка могла задовольнити хоча б частково потреби фермерів у визначенні хвороби сільськогосподарських рослин.

Для формування чіткої картини стану справ з визначенням хвороби рослин буде розглянуто в наступних підрозділах лабораторні підходи для виявлення хвороби та методи із використанням машинного та глибинного навчання. Визначення проблем, недоліків та переваг таких методів допоможе з'ясувати на якому етапі розвитку технологій зараз знаходиться вирішення цієї проблеми. Сприятиме створенню архітектури для розв'язку проблеми передбаченню хвороби з використанням гібридної експертної системи.

## 1.2 Огляд існуючих лабораторних підходів для виявлення хвороби рослин

Виявлення та ідентифікація хвороби сільськогосподарських культур може здійснюватися як прямими, так і непрямими лабораторними методами. Проблеми, переваги та недоліки таких методів проаналізовані для розуміння цілісної картини дослідження хвороби рослин. Вони можуть бути застосовані під час використання технологій комп'ютерного зору.

Пряме лабораторне виявлення захворювань включає молекулярні та серологічні методи, які можна використовувати для високопродуктивного аналізу, коли потрібно проаналізувати велику кількість зразків. У цих методах патогени, що викликають захворювання, такі як бактерії, гриби та віруси, виявляються безпосередньо, щоб забезпечити точну ідентифікацію захворювання/патогену. З іншого боку, непрямі методи визначають хвороби рослин за різними параметрами, такими як морфологічні зміни, зміна температури, зміна швидкості транспірації та леткі органічні сполуки, що виділяються зараженими рослинами.

### 1.2.1 Прямі методи виявлення

У 1984 і 1993 роках дві Нобелівські премії були присуджені за розробку моноклональних антитіл і ампліфікацію послідовностей нуклеїнових кислот відповідно за допомогою технології полімеразної ланцюгової реакції. [1] Зараз його широко використовують і для виявлення збудників хвороби рослин. Платформи для ПЛР у реальному часі також використовувалися для швидкої діагностики хвороби рослин на основі бактеріальних, грибкових та вірусних нуклеїнових кислот. Хоча методика ПЛР може забезпечити високу чутливість і специфічність завдяки точності ампліфікації ДНК, вона також обмежена відсутністю операційної надійності. ПЛР залежить від ефективності вилучення ДНК, а на ефективність впливають інгібітори, присутні в аналізі зразка, активність

полімерази, буфер для ПЛР та концентрація дезоксинуклеозидтрифосфату. [2] Крім того, застосування ПЛР для виявлення патогенів вимагає додаткової розробки для ініціації реплікації ДНК, що може обмежити практичне застосування цієї методики для польового відбору зразків хвороби.

Флуоресцентна гібридизація *in-situ*. Інший тип методу молекулярного виявлення — флуоресцентна гібридизація, яка застосовується для виявлення бактерій у поєднанні з мікроскопією та гібридизацією ДНК-зондів та цільових генів із зразків рослин. Через наявність у рослинах специфічних для патогену РНК розпізнавання цієї інформації може допомогти виявити патогенні інфекції в рослинах. [3] Однак, крім переваг, цей метод також має деякі недоліки, які ставлять під загрозу ефективність методики для виявлення хвороби рослин. Наприклад, хибнопозитивні результати з автофлуоресцентними матеріалами є поширеною проблемою, яка часто знижує специфічність. Точність і надійність сильно залежать від специфічності нуклеотидних зондів. Недостатнє проникнення, структура мішені або зонда вищого порядку (наприклад, тривимірна РНК, утворення петлі та шпильки та взаємодії РНК-білок), низький вміст РНК, фотовідбілювання також можуть викликати хибнонегативні результати і, отже, поставити під загрозу межу виявлення. [4]

Імуноферментний аналіз є ще одним молекулярним методом ідентифікації захворювань на основі антитіл і зміни кольору в аналізі. У цьому методі цільові антигени вірусів, бактерій і грибків зв'язуються з антитілами, що містять ферменти. [5] Виявлення можна візуалізувати на основі змін кольору в результаті взаємодії між субстратом та іммобілізованим ферментом. Для виявлення хвороби рослин було виготовлено ІФА для відбитків тканин рослин і пристрої для бічного потоку, які дозволяють виявляти їх на місці. Однак чутливість до бактерій відносно низька, що робить його корисним лише для підтвердження хвороби рослин

після появи візуальних симптомів, але не для раннього виявлення до появи симптомів хвороби. [2]

Імунофлуоресценція. Оптична техніка на основі флуоресцентної мікроскопії, яка використовується для аналізу мікробіологічних зразків. [6] Методика також може бути використана для виявлення патогенних інфекцій у тканинах рослин. Для цього методу зразки рослин фіксують на предметному склі мікроскопа тонкими зрізами тканини. Виявлення досягається шляхом додаванням флуоресцентного барвника зі специфічним антитілом для візуалізації розподілу цільової молекули по всьому зразку. [7] Подібно до інших методів, заснованих на флуоресценції, значною проблемою імунофлуоресценції є фотовідбілювання, яке призводить до хибнонегативних результатів. [7]

Проточна цитометрія. Лазерна оптична техніка, яка широко використовується для підрахунку та сортування клітин, виявлення біомаркерів та білкової інженерії. Ця техніка використовується для швидкої ідентифікації клітин, коли клітини проходять через електронний детекторний апарат у потоці рідини. [8] Перевагою цієї технології є можливість одночасного вимірювання кількох параметрів. Метод використовує лазерний промінь і вимірює розсіювання та флуоресценцію лазерного променя, відбитого від зразка. Хоча цитометрія в основному застосовувався для вивчення кінетики клітинного циклу та чутливості до антибіотиків, підрахунку бактерій, диференціації життєздатних бактерій від нежиттєздатних та характеристики бактеріальної ДНК та спор грибів, це все ще відносно нова методика для виявлення хвороби рослин. [9]

### 1.2.2 Непрямі методи виявлення

На додаток до прямих методів, розглянутих вище, для ідентифікації біотичних і абіотичних стресів, а також патогенних хворіб у сільськогосподарських культурах також використовувалися непрямі

методи, засновані на профілі стресу рослин. У зв'язку з цим були розроблені нові типи оптичних датчиків, які виявляють біотичні та абіотичні стреси в рослинах. Оптичні датчики надають детальну інформацію на основі різних електромагнітних спектрів і, таким чином, дозволяють прогнозувати здоров'я рослин. Термографія, флуоресцентне зображення та гіперспектральні методи є одними з найбільш сприятливих непрямих методів для виявлення хвороби рослин. [10]

Термографія. Дозволяє отримати зображення різниць температури поверхні листя і крон рослин. Інфрачервоне випромінювання може бути зафіксовано термографічними камерами і в подальшому проаналізовано різницю кольору. Попередні звіти продемонстрували, що на втрату води рослинами, що регулюються продихами, впливають фітопатогени. [11] Хворобу можна відстежувати за допомогою термографічного зображення та визначити кількість води, що виділяється, без впливу зовнішньої температури. Проте практичне застосування термографії для моніторингу захворювань обмежене через її високу чутливість до зміни умов навколишнього середовища під час вимірювань. [12] Крім того, термографічному виявленню не вистачає специфічності щодо захворювань, і тому його не можна використовувати для визначення типу інфекції або розрізнення захворювань, які викликають подібні термографічні моделі.

Флуоресцентне зображення. У цій техніці флуоресценцію хлорофілу вимірюють на листках як функцію падаючого світла. Зміна параметрів флуоресценції може бути використана для аналізу патогенних інфекцій на основі змін у фотосинтетичному апараті та реакціях фотосинтетичного транспорту електронів. Хоча вимірювання флуоресценції забезпечує чутливе виявлення відхилень у фотосинтезі, практичне застосування цієї техніки в польових умовах обмежене. [13]

Гіперспектральні техніки. Гіперспектральне зображення можна використовувати для отримання корисної інформації про здоров'я рослин у

широкому діапазоні спектру від 350 до 2500 нм. Таке зображення все частіше використовується для фенотипування рослин і ідентифікації хвороби сільськогосподарських культур у великомасштабному сільському господарстві. Метод дуже надійний і забезпечує швидкий аналіз даних зображень. Гіперспектральні методи широко використовуються для виявлення хвороби рослин шляхом вимірювання змін у відбивній здатності, що виникають у результаті змін біофізичних та біохімічних характеристик при зараженні. [14-15]

Газова хроматографія. Зовсім інший неоптичний непрямий метод виявлення хвороби рослин включає профілювання летких хімічних ознак заражених рослин. [16] Патогенні інфекції рослин можуть призвести до виділення специфічних летких органічних сполук, які вказують на тип стресу, який відчувають рослини. Це також дозволяє виявляти захворювання на різних стадіях на основі кількісної інформації, зібраної із зразка таких органічних сполук. [17] Однак, на відміну від системи візуалізації, яка може безпосередньо отримувати дані на полі, газова хроматографія вимагає відбору проб попередньо зібраних сполук протягом більш тривалого часу перед аналізом даних, що суттєво обмежує його застосування в польових умовах.

Виявлення хвороби рослин за допомогою портативних датчиків. Розроблено та комерціалізовано широкий спектр датчиків для різних застосувань, включаючи моніторинг навколишнього середовища та медичну діагностику. Аналіти хвороби рослин можуть бути виявлені за допомогою датчиків на основі електричних, хімічних, електрохімічних, оптичних, магнітних або вібраційних сигналів.

Сенсори спорідненості, хоча і ретельно вивчені, все ще залишаються в більшості випадків виключно лабораторним дослідженням. [18] Це можна пояснити недостатньою надійністю датчика, що в першу чергу пов'язано з погіршенням стану антитіл і ДНК/РНК-зонда з часом, а також вимогою



з'єднання з оптичними приладами. Молекулярні біосенсиори-маяки на основі ДНК потенційно можуть бути використані для тестування на місцях завдяки їхнім властивостям, таким як тестування в реальному часі та низька межа виявлення. [19]

Крім того, нижня межа виявлення, що забезпечується сенсорами на основі бактеріофагів, також є перспективною для застосування для виявлення живих бактеріальних патогенів з виявленням більшої кількості бактеріофагів. Однак ця методика не може бути використана для виявлення грибкових і вірусних збудників. [20]

З іншого боку, електрохімічні біосенсиори на основі ферментів, сконструйовані з використанням платформ наноматеріалів, мають більш високу специфічність і придатність для виявлення в реальному часі, ніж інші доступні технології. Електрохімічний ферментативний біосенсор також дозволяє виготовляти невеликі, портативні та прості у використанні пристрої для виявлення. Однак поточні проблеми полягають у ідентифікації, виробництві та очищенні ферментів, специфічних для кожної цільової легкої органічної сполуки, що виробляється інфікованими рослинами. [21]

Також багатообіцяючим є те, що ферментні та споріднені сенсори можуть бути виготовлені для виявлення кількох патогенів. [22]

### 1.2.3 Висновок щодо аналізу лабораторних підходів

Лабораторні підходи для визначення хвороби сільськогосподарських рослин, як бачимо, завжди набагато точніше будуть визначати конкретні патогени, грибки, віруси, що атакують рослину. Ці методи вже широко застосовуються в агропромисловому комплексі, але для застосування більшості з них необхідно мати велику кількість зразків, достатньо грошей та відповідних спеціалістів, що будуть займатися та обслуговувати технічне обладнання та проводити відповідні аналізи. Через це застосування таких

підходів неможливе для малого та середнього бізнесу агропромисловості. З перелічених вище методів лише використання біосенсорів з відповідним програмним забезпеченням може бути доступним для цього сектору. Проте комерціалізація цього методу ще не почалася, а прогнозована ціна поки може бути прийнятною лише для середнього та великого агробізнесу.

### 1.3 Огляд існуючих підходів з використанням експертних систем

Оскільки поставлена мета повністю відповідає задачі комп'ютерного зору, методи виявлення хвороби рослин на основі глибинного навчання можна розглядати як застосування відповідних класичних мереж у сфері сільського господарства. На рисунку 1.1 зображено схему структури методів виявлення хворіб рослин, які були застосовані попередніми дослідниками. Аналіз найкращих з них (на схемі виділено жирним) наведено в наступних розділах.



Рисунок 1.1 – Структура методів виявлення хворіб рослин на основі глибинного навчання

### 1.3.1 Класифікаційна мережа

У реальному природньому середовищі великі відмінності у формі, розмірі, текстурі, кольорі, фоні, компонуванні та освітленні зображень рослин роблять розпізнавання важким завданням. Завдяки потужним можливостям вилучення ознак, використання моделі класифікації на основі згорткових нейонних мереж стало найбільш частим для класифікації хвороби рослин. Існуючі мережі класифікації хвороби рослин здебільшого використовують зрілі мережеві структури комп'ютерного зору, включаючи AlexNet, GoogleLeNet, VGGNet, ResNet, InceptionV4, DenseNet, MobileNet і SqueezeNet. Існують також деякі дослідження, які розробляють мережеві структури на основі практичних проблем. Відповідно до відмінності завдань, досягнутих методом мережі класифікації, її використання можна розділити на три підкатегорії: як екстрактора ознак, для безпосередньої класифікації та для локалізації уражень.

Використання мережі для вилучення особливостей. У ранніх дослідженнях методів класифікації хвороби рослин, заснованих на глибинному навчанні, багато дослідників скористалися перевагами потужної можливості вилучення особливостей згорткових нейронних мереж (CNN), і ці методи були поєднані з традиційними класифікаторами. Спочатку зображення вводяться в попередньо підготовлену мережу для отримання особливостей зображення, а потім вихідні результати вводяться в звичайний класифікатор машинного навчання, наприклад, метод опорних векторів (SVM). Запропонував архітектуру згорткової нейронної мережі для вилучення особливостей зображень під час виконання експериментів з використанням класифікаторів SVM з різними ядрами та дескрипторами ознак, такими як локальний двійковий шаблон та узагальнене дерево пошуку, результати експерименту підтвердили ефективність підходу. [23] Висунуто ідею мета-архітектури на основі CNN з різними функціями вилучення особливостей, а вхідні зображення включали здорові та

інфіковані рослини, які були ідентифіковані як відповідні класи після проходження мета-архітектури. [24] Було визначено і класифіковано дев'ять різних типів захворювань рису, використовуючи ознаки, вилучені з моделі глибокої згорткової мережі і введені в SVM, точність моделі досягла 97,5%. [25]

Використання мережі класифікації. Згідно з наявними дослідницькими роботами, таке застосування можна розділити на класифікацію оригінальних зображень та класифікацію за визначенням регіонів інтересів (ROI).

Класифікація оригінальних зображень, тобто безпосередньо застосувати всі наявні в датасеті зображення хвороби рослин для навчання та валідації мережі. Для цього було запропоновано ефективну глибинну модель CNN, а передавальне навчання використовується для точного налаштування моделі попереднього навчання. Види комах були класифіковані за трьома загальнодоступними наборами даних про комах з середньою точністю в 96,75%. [26] Використано ResNet50 для виявлення хвороби рослин. Замість стандартної функції втрат перехресної ентропії була використана функція втрати фокусу, а для визначення ступеня ураження листя використовувався метод оптимізації Адама, точність досягла 95,61%. [27]

Класифікація за визначенням регіонів інтересів. Спочатку необхідно з'ясувати чи наявні ураження на зображенні рослини і відповідно виділити регіони інтересів, тобто область з хворобою. Потім вводимо ROI в мережу, щоб визначити категорію хвороби. Така модель використовувала нову тривимірну глибинну мережу та метод візуалізації карти чіткості для ідентифікації здорових та інфікованих зразків гнилі стебла сої, точність класифікації досягла 95,73%. [28]

Використання мережі для локалізації уражень. Як правило, мережа класифікації може лише класифікувати мітку зображення (цільовий клас

зображення). Насправді, вона також може досягти локалізації уражень і піксельної класифікації шляхом поєднання різних прийомів і методів. Таким чином, можна виділити три основні алгоритми локалізації: розсувне вікно, теплова карта та багатозадачна мережа.

Розсувне вікно – це найпростіший і інтуїтивно зрозумілий метод для грубого визначення місця ураження. Зображення у розсувному вікні вводиться в мережу класифікації для виявлення хвороби рослин шляхом зайвого проходження по вихідному зображенню через вікно меншого розміру. Нарешті, всі розсувні вікна з'єднуються для отримання результатів локалізації ураження. Така модель використовувала мережу класифікації CNN з використанням цього методу, щоб побудувати основу для автоматичного навчання характеристик, злиття ознак, розпізнавання та розрахунку регресії розташування хвороби і видів шкідників, а точність розпізнавання 38 поширених симптомів у польових умовах становила 50–90%. [29]

Теплова карта – це зображення, яке відображає важливість кожного регіону на зображенні, чим темніший колір, тим важливіший. У сфері виявлення хвороби рослин, чим темніший колір на тепловій карті, тим більша ймовірність того, що це ураження. У 2017 році дослідники навчили CNN складати теплову карту, щоб показати ймовірність зараження в кожному регіоні на зображеннях хвороби кукурудзи, і ці теплові карти були використані для класифікації повних зображень, поділяючи кожне на таке, що містить або не містить заражене листя. [30] Експерименти показують, що точність тестового набору даних становить 96,7%. У 2019 році використано метод теплової карти для отримання точних контурних областей хвороби кукурудзи, модель може точно відобразити ураження в міліметровій шкалі із зображень, зібраних дроном, з точністю 99,79%. [31]

Багатозадачна мережа. Якщо базова класифікаційна мережа не додає жодних нових ознак, вона могла б реалізувати лише класифікацію на рівні

зображення. Таким чином, щоб точно визначити місце розташування хвороби рослин, спроектована мережа повинна додавати додаткову гілку, тому дві гілки ділитимуться результатами вилучення особливостей одна з одною. Тому мережа матиме класифікацію та сегментацію хвороби рослин, утворюючи багатозадачну мережу. Вона враховує характеристики обох мереж. Для сегментації гілок мережі кожен піксель на зображенні можна використовувати як зразок для навчання мережі. Таким чином, багатозадачна мережа не тільки використовує гілки сегментації для виведення конкретних результатів сегментації уражень, але також значно знижує вимоги мережі класифікації для зразків. Побудовано модель VGNet, керовану деконволюцією, щоб ідентифікувати хвороби листя рослин, які легко порушувалися тінями, оклюзіями та інтенсивністю світла. Деконволюція була використана, щоб направляти класифікатор CNN для зосередження на місцях ураження. [32] Результати тесту показують, що точність ідентифікації захворювання становить 99,19%, точність піксельної сегментації ураження – 94,66%, а сама модель має хорошу стійкість в умовах оклюзії, слабкого освітлення та інших перешкодах.

### 1.3.2 Мережа виявлення

Позиціонування об'єктів – одне з основних завдань у сфері комп'ютерного зору. Це також найближче завдання до виявлення хвороби рослин у традиційному розумінні. Його мета – отримати точну інформацію про місцезнаходження та категорію об'єкта. В даний час методи виявлення об'єктів, засновані на глибинному навчанні, з'являються все більше і більше. Мережу виявлення хвороби рослин на основі глибинного навчання можна розділити на: двоетапну мережу, представлену R-CNN; [33] одноетапна мережа, представлена SSD та YOLO. [34] Основна відмінність між цими двома мережами полягає в тому, що двоетапна мережа повинна спочатку створити кандидата, який може містити пошкодження, а потім далі

виконати процес виявлення об'єкта. На відміну від цього, одноетапна мережа безпосередньо використовує ознаки, отримані в мережі, щоб передбачити розташування та клас уражень.

Виявлення хвороби рослин на основі двоетапної мережі. Основний процес двоетапної мережі виявлення (R-CNN) полягає в тому, щоб спочатку отримати карту ознак вхідного зображення і визначити регіони інтересів. Потім карта особливостей об'єднана з ROI відправляється на вхід в мережу. В результаті, на виході отримується місцезнаходження та результати класифікації уражень. Тому, відповідно до характеристик виявлення хвороби рослин, звичайні методи часто покращують карту ознак, коефіцієнт прив'язки, об'єднання ROI та функцію втрат. У 2017 році дослідники вперше використали R-CNN для безпосереднього визначення місцезнаходження хвороби томатів, у поєднанні з глибинною мережею вилучення особливостей, такими як VGG-Net і ResNet, значення точності досягло 85,98% у наборі даних, що містить 5000 хворіб томатів 9 категорій. [35] У 2019 році було запропоновано структуру R-CNN для автоматичного виявлення хвороби бурякової плямистості листя шляхом зміни параметрів моделі CNN, для навчання та тестування було залучено 155 зображень. [36] Результати показують, що загальний рівень правильної класифікації цього методу становить 95,48%. Інші дослідники представили метод швидкого виявлення хвороби рису, заснований на поєднанні кластеризації і R-CNN. [37] Результати застосування 3010 зображень показали, що: точність і час виявлення тріщини рису, бактеріального опіку та фітофторозу становить 96,71% і 0,65с, 97,53% і 0,82с, 98,26% і 0,53с відповідно. Запропоновано модель, засновану на самостійно створеному наборі даних про хвороби виноградного листя і алгоритмі виявлення R-CNN. [38] Представлені модулі InceptionV1 та Inception-ResNet-v2. Запропонована модель досягла більш високої здатності вилучення особливостей, а точність склала 81,1%, швидкість виявлення – 15,01 кадрів в секунду. Застосування двоетапної

мережі значно покращило швидкість передбачення, щоб покращити реальний час і практичність системи виявлення. Проте в порівнянні з одноетапною мережею вона все ще недостатньо стисла, і швидкість передбачення все ще залишається недостатньою.

Виявлення хвороби рослин на основі одноетапної мережі. Одноетапний алгоритм виявлення об'єктів усунув етап знаходження регіонів інтересів, але безпосередньо розширює виявлення основної мережі класифікації. Таким чином значно покращується швидкість передбачення. Одноетапна мережа ділиться на два типи: SSD і YOLO, обидва з яких використовують ціле зображення на вхід мережі і повертають місцезнаходження та категорію, до якої належить знайдений об'єкт.

Порівняно з традиційною згортковою нейронною мережею, SSD використовує VGG16 як основну мережу і додає мережу вилучення особливостей, щоб отримати додаткові ознаки з різних шарів. Створено набір даних PlantDoc для виявлення хвороби рослин. [39] Враховуючи, що програма повинна працювати на мобільному телефоні в режимі реального часу, для спрощення параметрів моделі було створено додаток на основі MobileNets і SSD. Представлено метод виявлення екземплярів багатомасштабного злиття ознак на основі згорткової нейронної мережі, який удосконалено на основі SSD для виявлення фітофторозу кукурудзи на складному фоні. [40] Запропонований метод поєднував попередню обробку даних, об'єднання ознак, обмін ознаками, виявлення захворювань та інші етапи. Середня точність нової моделі вища від 71,80 до 91,83%, ніж у оригінальної моделі SSD. Кількість кадрів в секунду, що може обробляти модель, також покращився з 24 до 28,4, досягнувши стандарту виявлення в реальному часі.

YOLO розглядає завдання виявлення як проблему регресії та використовує глобальну інформацію для прямого прогнозування обмежувальної рамки та категорії об'єкта для наскрізного виявлення. YOLO



може досягти глобальної оптимізації та значно покращити швидкість виявлення, задовольнивши високу точність. Представлено метод виявлення шкідників і хвороби на зображеннях, знятих у неконтрольованих умовах у чайних садах. [41] YOLOv3 використовувався для виявлення шкідників і хвороби. Забезпечуючи доступність системи в режимі реального часу, було досягнуто середньої точності в приблизно 86%. Інші дослідники об'єднали просторові піраміди за допомогою покращеної мережі YOLOv3. [42] Деконволюція реалізована за допомогою комбінації операції з підвищенням вибірки та згортки, що дає змогу алгоритму ефективно виявляти на зображенні зразки шкідників невеликого розміру та зменшує проблему відносно низької точності розпізнавання через різноманітність шкідників сільськогосподарських культур. Середня точність розпізнавання може досягати 88,07% при тестуванні 20 класів шкідників, зібраних з реального світу.

### 1.3.3 Мережа сегментації

Перетворює завдання виявлення хвороби рослин на семантичну і навіть екземплярну сегментацію уражень і нормальних областей. Вона не тільки тонко розділяє зону ураження, але також отримує місце розташування, категорію та відповідні геометричні властивості (включаючи довжину, ширину, площу, контур, центр тощо). Їх можна розділити на: мережі повної згортки (FCN) і масковані R-CNN.

Нейронна мережа повної згортки є основою сегментації зображення. На даний момент майже всі моделі семантичної сегментації засновані на FCN. Мережа спочатку витягує та кодує ознаки вхідного зображення за допомогою згортки, а потім поступово відновлює зображення об'єкта до розміру вхідного зображення шляхом деконволюції або збільшенням вибірки. Виходячи з відмінностей у структурі мережі FCN, методи

сегментації хвороби рослин можна розділити на звичайний FCN, U-net і SegNet. [43]

Звичайний FCN. Представлено новий метод сегментації хвороби листя кукурудзи на основі нейронної мережі повної згортки, щоб дослідити гіпотезу: традиційний комп'ютерний зір сприйнятливий до різного освітлення та складного фону. [44] Точність сегментації досягла 96,26%. Також запропоновано метод сегментації хвороби рослин на основі покращеного FCN. [45] У цьому методі шар згортки використовувався для вилучення багатоваріаційної інформації про особливості з вхідного зображення ураження листя кукурудзи, а розмір і роздільна здатність вхідного зображення були відновлені за допомогою операції деконволюції. Порівняно з оригінальним методом FCN була гарантована не тільки цілісність ураження, а й виділена сегментація невеликої ділянки ураження, а рівень точності досягнув 95,87%.

U-net – це не тільки класична структура FCN, але й типова структура кодера-декодера. Він характеризується введенням додаткового шару, що об'єднує карти особливостей з етапу кодування та етапу декодування – це корисно для відновлення деталей сегментації. Дослідник Лін з колегами використовували згорткову нейронну мережу на основі U-net для сегментації 50 листків борошнистої роси огірків, зібраних у природному середовищі. [46] У порівнянні з оригінальною U-net, шар нормалізації був доданий за кожним шаром згортки, що робило нейронну мережу нечутливою до першочергової ініціалізації параметрів моделі. Експеримент показує, що нейронна мережа на основі U-net може точно сегментувати борошнисту росу на листках огірків на рівні пікселів із середньою точністю пікселів 96,08%, що перевершує існуючі методи K-середніх, Random-forest і GBDT. Метод U-net може сегментувати область ураження на складному фоні, але при цьому має хорошу точність та швидкість з меншою кількістю зразків для навчання.

SegNet – це також класична структура кодер-декодера. Його особливість полягає в тому, що операція підвищення вибірки в декодері використовує переваги індексу найбільшої операції об'єднання в кодері. Представлено метод сегментації зображень для безпілотних літальних апаратів. [47] Видимі та інфрачервоні зображення (480 зразків з кожного діапазону) були сегментовані за допомогою SegNet для визначення чотирьох категорій: тіні, земля, здорові та симптоматичні виноградні лози. Показники виявлення запропонованого способу на виноградних лозах і листках становили 92% і 87% відповідно.

Масковані R-CNN – є одним з найбільш часто використовуваних методів сегментації екземплярів зображення на даний момент. Його можна розглядати як багатозадачний метод навчання, заснований на мережі виявлення та сегментації. Коли кілька уражень одного типу перекриваються, сегментація може їх розділити та додатково підрахувати їх кількість. Однак семантична сегментація часто розглядає кілька уражень одного типу як єдине ціле. Стюарт та інші дослідники навчали модель маскованої R-CNN сегментувати ураження кукурудзи, що міститься північним листям на зображенні безпілотного літального апарату. [48] Навчена модель може точно виявити та сегментувати одне ураження. Крім того, деякі дослідження поєднують масковані R-CNN з мережами виявлення об'єктів для виявлення хвороби рослин. Використано дві різні моделі, R-CNN і масковану R-CNN, в яких R-CNN використовувався для визначення класу хвороби томатів, а маскована R-CNN використовувався для виявлення та сегментації розташування та форми зараженої області. [49] Результати показали, що запропонована модель дозволяє швидко та точно визначати 11 класів хвороби томатів, а також розділити локалізацію та форму заражених ділянок. Маскована R-CNN досягла високого рівня точності 99,64% для всіх класів хвороби томатів.

### 1.3.4 Висновки щодо досліджених структур нейронних мереж

У порівнянні з мережевими методами класифікації та виявлення, метод сегментації має переваги в отриманні інформації про місцезнаходження ураження. Однак, як і мережа виявлення, вона вимагає багато даних з анотаціями, а результат її роботи – області піксель за пікселем, обчислення яких зазвичай вимагає великих зусиль і витрат.

Проблеми з якими зіткнулися попередні дослідники:

а) невеликий розмір набору даних. В даний час методи глибинного навчання широко використовуються в різних задачах комп'ютерного зору, виявлення хвороби рослин, як правило, розглядається як специфічне застосування в галузі сільського господарства. Доступних зразків хвороби сільськогосподарських рослин занадто мало. У порівнянні з відкритими стандартними бібліотеками, набори даних, які збираються самостійно, мають невеликі розміри, а їх маркування стає великою проблемою. Порівняно з більш ніж 14 мільйонами зразків у наборах даних ImageNet, найбільш критичною проблемою виявлення хвороби рослин є проблема малих вибірок. На практиці деякі хвороби рослин мають низьку захворюваність і високу вартість отримання зображення хвороби, що призводить до збирання лише кількох або десятків навчальних даних, що обмежує застосування методів глибинного навчання у сфері виявлення хвороби рослин і шкідників;

б) проблема тонкої ідентифікації. Між класами є нечіткість, тобто об'єкти різних класів мають певну схожість. Існує багато детальних класифікацій біологічних підвидів і підкласів різних видів хвороби і шкідників, а також є деяка подібність біологічної морфології та життєвих звичок серед підкласів, що призводить до проблеми дрібного визначення «міжкласової подібності». Барбеда вважав, що можуть виникати подібні симптоми, які навіть фітопатологи не могли правильно розрізнити. [50] Фон зображення може бути дуже складним, заважатиме знаходити об'єкти, які

визначає мережа. У деякій літературі це питання часто ігнорується, оскільки зображення фіксуються в контрольованих умовах. Покладаючись на існуючі методи глибинного навчання, неможливо ефективно ідентифікувати дрібні характеристики хвороби. Під час застосування результатів досліджень на практиці в сільському господарстві виникали технічні труднощі, такі як низька точність ідентифікації та надійність визначення. Існуючі дослідження придатні лише для детальної ідентифікації меншої кількості класів хвороби. Вони не можуть вирішити проблему великомасштабної, багатокатегоріальної, точної та ефективної ідентифікації хвороби. Також варто зазначити, що їх важко розгорнути безпосередньо на мобільні термінали розумного сільського господарства;

в) продуктивність виявлення під впливом освітлення та оклюзії. Проблеми з освітленням. Попередні дослідження збирали зображення хвороби рослин переважно в освітлювальних боксах у приміщенні. Хоча цей метод може ефективно усунути вплив зовнішнього світла для спрощення обробки зображень, він значно відрізняється від зображень, зібраних під реальним природним освітленням. Оскільки природне освітлення змінюється дуже динамічно, а діапазон, у якому камера може приймати динамічні джерела світла, обмежений, легко спричинити спотворення кольору зображення. Проблема оклюзії. Більшість дослідників навмисно уникають розпізнавання хвороби рослин у складних середовищах. [51] Вони фокусуються лише на одному фоні. Використовують метод безпосереднього перехоплення області зібраних зображень, але рідко розглядають проблему оклюзії. Як наслідок, точність розпізнавання під оклюзією є низькою, а практичність значно зменшується.

#### 1.4 План проведення наукового дослідження

Виходячи із детального дослідження ресурсів та аналізу предметної області було деталізовано задачу, на якій базується реалізація практичної частини роботи.

План проведення наукового дослідження:

- а) дослідити сучасні архітектури моделей нейронних мереж для сегментації зображень. Проаналізувати концепти застосування передавального навчання як одного з найкращих методів машинного навчання для класифікації рослин;
- б) визначити сільськогосподарські культури для проведення експерименту класифікації;
- в) розширити набір даних зображень визначених культур за допомогою лінійних перетворень, накладання світлових та інших ефектів;
- г) підготувати датасет для навчання мережі сегментації;
- д) розробити мережу сегментації для виділення уражених листків хворих рослин;
- е) Підготувати датасет сегментованих зображень для навчання кінцевої класифікаційної мережі;
- ж) Розробити кінцеву класифікаційну мережу із застосуванням передавального навчання для виявлення хвороби сільськогосподарських рослин.

## 2 ДОСЛІДЖЕННЯ СУЧАСНИХ ТЕХНОЛОГІЙ ЕКСПЕРТНИХ СИСТЕМ ТА ПЕРЕДАВАЛЬНОГО НАВЧАННЯ

### 2.1 Основні концепції гібридних експертних систем

Експертна система - це інтелектуальна програма, здатна робити логічне виведення на основі знань в конкретній предметній області, яке забезпечує вирішення специфічних задач. [52] У 1959 році Ньюелл, Шоу та Саймон розробили загальний розв'язувач проблем, який є підсумком мислення людей для вирішення проблем. [53] Вони виявили, що коли люди вирішують проблеми, діяльність мислення включає три кроки: розробка приблизного плану; розв'язування задачі за планом використовуючи аксіоми, теореми, які запам'ятала людина; здійснення процесу вирішення проблеми, постійно аналізуючи метод і мету та переглядаючи план.

У 1965 році відповідно до вимог Національного управління з аеронавтики і дослідження космічного простору Стенфордський університет успішно розробив систему Dendral. [54] За попередньо введеним правилом, система Dendral може автоматично генерувати молекулярні структури, які можуть інтерпретувати спектральні дані. Система була першою успішною програмою, що використовує знання самої проблеми, а не комплексну технологію пошуку. Dendral підказує дослідникам штучного інтелекту, що розумна поведінка покладається не тільки на методи втручання, але й на знання, які використовуються для їх втручання. Дослідники починають будувати програму, яка використовує правила коду для представлення знань для вирішення проблеми введення.

Відтоді MIT розробив систему Macsyma як помічник математика, яка використовує евристики для перетворення алгебраїчних виразів. [55] Після безперервного розширення він може вирішувати понад 600 видів математичних задач, включаючи обчислення, операцію з матрицею, розв'язування рівнянь тощо. Успішний розвиток цих систем робить

експертну систему широко зацікавленою в наукових колах та інженерії. Багато дослідників у процесі розробки експертних систем усвідомили, що представлення знань, використання знань і отримання знань є трьома основними проблемами систем штучного інтелекту.

Наприкінці 1980-х років експертні системи почали проникати в бачення людей. Завдяки своїй вищій здатності представляти описову та поведінкову інформацію про об'єкт, експертна система, заснована на фреймворку, могла впоратися з більш складними проблемами, ніж експертна система на основі правил. У той же час дослідження експертної системи наштовхнулося на труднощі, виявляючи дефекти систем штучного інтелекту, такі як вузькі сфери застосування, труднощі з засвоєнням знань, механізм міркування тощо. Дослідникам необхідно було позбутися дилеми, досліджуючи основну точку зору та використовуючи нові методики та теорії.

Основна структура експертної системи складається з таких частин: база знань, робоча пам'ять, машина для міркувань, інтерпретатор та інтерфейс взаємодії людини та комп'ютера. База знань використовується для зберігання досвіду експертної системи, включаючи факти та правила. У процесі побудови база знань повинна мати можливість здобувати нові знання, виражаючи та зберігаючи їх у спосіб, який може виконати комп'ютер. Робоча пам'ять відповідає за зберігання факту введення. Машина міркувань співставляє факти в робочій пам'яті зі знаннями і отримує нову інформацію. Проміжна інформація, отримана під час обробки, також повинна зберігатися в блоці зберігання. Інтерпретатор відповідає за інтерпретацію результатів виводу системи висновку, включаючи пояснення правильності та причини висновку.

З розвитком нейронних мереж і статистичного навчання машинне навчання стало новою точкою дослідження штучного інтелекту. Природно, люди думали, що якби технологія машинного навчання застосувати до



експертної системи, то ефективність міркувань експертної системи підвищилася б. Нечітка логіка, як ще одна нова область, була також застосована до експертної системи. Сьогодні попит на експертні системи ще більше зростає, і люди прагнуть використовувати системи для вирішення більш складних проблем.

## 2.2 Проблеми і завдання нейронних мереж

Нейронні мережі – це штучні адаптивні системи, які надихаються процесами функціонування людського мозку. Це системи, які здатні модифікувати свою внутрішню структуру відповідно до цілі функції. [56] Вони особливо підходять для розв’язування задач нелінійного типу, будучи здатними реконструювати нечіткі правила, які керують оптимальним рішенням цих задач.

Базовими елементами нейронних мереж є вузли, так звані елементи обробки, і з’єднання. Кожен вузол має свій власний вхід, з якого він отримує повідомлення від інших вузлів та/або із середовища та власний вихід, з яким він спілкується, це може бути інший вузол або зовнішнє середовище. Нарешті, кожен вузол має функцію  $f$ , за допомогою якої він перетворює власний глобальний вхід у вихідний. Кожне з’єднання характеризується силою, з якою пари вузлів збуджуються або гальмуються. Позитивні значення вказують на збудливі зв’язки, негативні – на гальмівні. З’єднання між вузлами можуть змінюватися з часом. [57] Ця динаміка запускає процес навчання у всій нейронній мережі. Спосіб, за допомогою якого вузли змінюють себе, називається «законом навчання». Повна динаміка мережі прив’язана до часу. [58] Дані – це середовище, яке діє на нейронну мережу. Таким чином, процес навчання є одним із ключових механізмів, що характеризують системи нейронних мереж, які вважаються адаптивними системами обробки. Процес навчання — це один із способів адаптації

зв'язків мережі до структури даних, що складають середовище, і, отже, спосіб «розуміти» середовище та відносини, які його характеризують.

Нейрони можуть бути організовані будь-яким топологічним способом (наприклад, одно- або двовимірні шари, тривимірні блоки або багатовимірні структури), залежно від якості та кількості вхідних даних. Найпоширеніші нейронні мережі складаються в так звану топологію прямого зв'язку. [59] Певна кількість елементів обробки поєднується з вхідним шаром, як правило, залежно від кількості вхідних змінних. Інформація пересилається на один або кілька прихованих шарів, що працюють в нейронній мережі. Вихідний шар, як останній елемент цієї структури, забезпечує результат. Вихідний шар містить лише один елемент обробки, незалежно від того, чи є результат двійковим значенням або одним числом.

Усі елементи обробки в межах нейронної мережі зв'язані з іншими елементами обробки в їх околицях. Спосіб встановлення цих зв'язків може відрізнятися між підтипами нейронних мереж. [60] Кожне з цих з'єднань має так звану вагу, яка змінює вхідне або вихідне значення. Значення цих ваг зв'язку визначається в процесі навчання. Ця функціональність є основою для можливості навчання нейронних мереж. Тому важливо розуміти, що в алгоритмі немає правил класифікації. Мережа просто вчиться розуміти та класифікувати шаблони введення на прикладах. Базові нейронні мережі зазвичай можна отримати за допомогою пакетів статистичних комп'ютерних програм. Деякі компанії пропонують спеціалізоване програмне забезпечення для роботи з різними нейронними мережами, наприклад, NeuralWorks Professional або інструмент Clementine Data Mining. [61-62] Ці програмні пакети повинні бути гнучкими та простими у використанні для широкого використання.

### 2.3 Мережі сегментації, їх структура і застосування

За останні роки найбільш успішні підходи семантичної сегментації були засновані на згорткових нейронних мережах (CNN). Ранні підходи обмежували потік вихідних даних сегментації лише спрямуванням їх знизу вгору, за яким слідувала класифікація зацікавлених регіонів на основі CNN. Замість того, щоб спочатку класифікувати цілі регіони, підхід дослідників виконує піксельну класифікацію з використанням функцій CNN, що походять із кількох масштабів, з подальшою агрегацією цих шумних передбачень пікселів у більш великі піксельні області. [63]

Запровадження так званих повністю згорткових мереж для сегментації семантичного зображення. Відкрито широкий спектр досліджень семантичної сегментації з використанням наскрізного навчання. [64] Ці ж дослідники далі переформулювали популярну архітектуру VGG як повністю згорткову мережу, що дозволило використовувати попередньо навчені моделі для цієї архітектури. Щоб покращити продуктивність сегментації на кордонах об'єктів, були додані з'єднання пропуску, які дозволяють інформації поширюватися безпосередньо від ранніх шарів з високою роздільною здатністю до більш глибоких шарів.

Об'єднання шарів у FCN відіграє вирішальну роль для збільшення розміру сприйнятливих поля пізніших одиниць, а разом з цим і ефективності класифікації. Однак у них є недолік, що результуючі мережеві виходи мають нижчу роздільну здатність. Щоб подолати це, були запропоновані різні стратегії. Деякі підходи витягують елементи з проміжних шарів за допомогою певних з'єднань пропуску. Науковці запропонували мережу кодера-декодера. [65] Кодер обчислює представлення об'єктів низької розмірності за допомогою послідовності операцій об'єднання та згортки. Декодер, який розміщений поверх кодера, потім вивчає масштабування цих малорозмірних функцій за допомогою

наступних операцій роз'єднання та деконволюції. Аналогічно, використано згортки замість деконволюцій у мережі декодера. [66] На відміну від цього, підхід в цьому науковому дослідженні, що описаний в розділі 3.2, зберігає інформацію з високою роздільною здатністю по всій мережі, зберігаючи окремий потік обробки високої роздільної здатності.

Багато підходів застосовують операції згладжування до вихідних даних CNN, щоб отримати більш послідовні прогнози. Найчастіше на виході мережі застосовуються умовні випадкові поля. [67] Нещодавно деякі роботи апроксимували виведення середнього такого поля за допомогою спеціалізованих мережових архітектур. Інші підходи до згладжування прогнозів мережі включають перетворення домену та згладжування на основі суперпікселів. Підхід в цьому дослідженні здатний швидко поєднувати інформацію з високою та низькою роздільною здатністю, що призводить до безперебійного прогнозування вихідних даних. Тому експерименти з додатковим згладжуванням умовних випадкових полів не призвели до значного покращення продуктивності.

Успіх архітектури AlexNet у ImageNet Large-Scale Visual Classification Challenge, став проривом для всієї спільноти зацікавлених архітектурами CNN. [68] Глибина мережі постійно збільшувалася, спочатку за допомогою популярної мережі VGG, а потім за допомогою пакетної нормалізації з GoogleNet. Останнім часом багато програм комп'ютерного зору прийняли архітектуру ResNet, що часто призводить до підвищення продуктивності значущості порівняно з попередніми мережевими архітектурами. Усі ці події показують, наскільки важливою є правильна архітектура. Однак поки що більшість із цих мереж були спеціально розроблені для завдання класифікації, у багатьох випадках включаючи етап попередньої підготовки до вищезгаданих змагань класифікації зображень. Як результат, деякі з їхніх варіантів моделей можуть сприяти неоптимальній продуктивності при виконанні піксельних завдань, таких як семантична сегментація.

Мережі прямого поширення. Донедавна більшість мереж прямого поширення, наприклад VGG-моделі, склалися з лінійної послідовності шарів. [69] Кожен рівень у такій мережі обчислює функцію  $F$ , а вихід  $x_n$   $n$ -го шару обчислюється як

$$x_n = F(x_{n-1}; W_n), \quad (2.1)$$

де  $W_n$  – параметри шару. Цей клас мережевих архітектур називається традиційними мережами прямого поширення.

Залишкові нейронні мережі. Попередні дослідники помітили, що поглиблення традиційних мереж прямого поширення часто призводить до збільшення втрат під час навчання. Теоретично, втрата навчання дрібної мережі повинна бути верхньою межею для втрати навчання відповідної глибокої мережі. Це пов'язано з тим, що збільшення глибини за рахунок додавання шарів суворо збільшує виразну силу моделі. Глибока мережа може виражати всі функції, які може виразити вихідна неглибока мережа, використовуючи відображення ідентичностей для доданих шарів. Отже, глибока мережа повинна працювати принаймні так само добре, як і більш дрібна модель щодо даних навчання. Порушення цього принципу означало, що поточні алгоритми навчання мають труднощі з оптимізацією дуже глибоких традиційних мереж прямого поширення. Запропоновано залишкові мережі, які демонструють значно покращені характеристики навчання, дозволяючи більш глибокі архітектури нейронних мереж, які раніше були недосяжними.

Залишкова мережа складається з послідовності залишкових одиниць. При чому вихід  $x_n$   $n$ -ої залишкової одиниці в мережі обчислюється як

$$x_n = x_{n-1} + F(x_{n-1}; W_n), \quad (2.2)$$

де  $F(x_{n-1}; W_n)$  – залишок, який параметризується  $W_n$ . Таким чином, замість того, щоб безпосередньо обчислювати вихід  $x_n$ ,  $F$  обчислює лише залишок, який додається до входу  $x_{n-1}$ . Зазвичай цю конструкцію називають

з'єднанням з пропуском, оскільки існує з'єднання від входу  $x_{n-1}$  до виходу  $x_n$ , яке пропускає фактичне обчислення  $F$ .

Емпірично було помічено, що залишкові мережі мають кращі навчальні властивості в порівнянні з традиційними мережами прямого поширення. Це можна пояснити покращеним градієнтним потоком всередині мережі. Щоб зрозуміти це, розглянемо  $n$ -й і  $m$ -й залишкові одиниці в мережі, де  $m > n$ , тобто  $m$ -й блок ближче до вихідного рівня мережі. Застосовуючи рекурсію формули (2.2) кілька разів, дослідники показали, [70] що вихід  $m$ -ої залишкової одиниці допускає подання у вигляді

$$x_m = x_n + \sum_{i=n}^{m-1} F(x_i; W_{i+1}). \quad (2.3)$$

Крім того, якщо  $l$  – це функція втрат, яка використовується для навчання мережі, можна застосувати ланцюгове правило обчислення і виразити похідну втрат  $l$  щодо виходу  $x_n$   $n$ -ої залишкової одиниці як

$$\frac{\partial l}{\partial x_n} = \frac{\partial l}{\partial x_m} \frac{\partial x_m}{\partial x_n} = \frac{\partial l}{\partial x_m} + \frac{\partial l}{\partial x_m} \sum_{i=n}^{m-1} \frac{\partial F(x_i; W_{i+1})}{\partial x_n}. \quad (2.4)$$

Видно, що оновлення ваг залежить від двох джерел інформації з формулами:

$$\frac{\partial l}{\partial x_m}, \quad (2.5)$$

$$\sum_{i=n}^{m-1} \frac{\partial F(x_i; W_{i+1})}{\partial x_n}. \quad (2.6)$$

У той час як кількість інформації, яка міститься в формулі (2.6), може суттєво залежати від глибини  $n$ , перша дозволяє градієнтний потік, який не залежить від глибини. Таким чином, градієнти можуть безперешкодно перетікати від більш глибокої одиниці до більш дрібної. Це робить можливим навчання навіть надзвичайно глибоких залишкових нейронних мереж.

Саме така архітектура нейронної мережі була обрана для задачі сегментації ураженого листя рослин. Детальніше про переваги та проблеми тренування моделі описано в розділі 3.2.

## 2.4 Концепції передавального навчання

Передавальне навчання – це дослідницька проблема в машинному навчанні, яка зосереджується на зберіганні знань, отриманих під час вирішення однієї проблеми, і застосування їх до іншої, пов'язаної проблеми.

Хоча традиційні технології машинного навчання досягли великого успіху і успішно застосовуються в багатьох практичних застосуваннях, вони все ще мають деякі обмеження для певних реальних сценаріїв. Ідеальний сценарій машинного навчання полягає в тому, що існує велика кількість позначених навчальних екземплярів, які мають такий самий розподіл, як і тестові дані. Однак збір достатньої кількості навчальних даних часто є дорогим, трудомістким або навіть нереальним у багатьох сценаріях. Напівконтрольоване навчання може частково вирішити цю проблему, послабивши потребу в масових позначених даних. Як правило, підхід з напівнаглядом вимагає лише обмеженої кількості позначених даних, і він використовує велику кількість немаркованих даних для підвищення точності навчання. Але в багатьох випадках також важко зібрати немарковані екземпляри, що зазвичай робить отримані традиційні моделі незадовільними. Як вже було з'ясовано, що для проблеми розпізнавання хвороби сільськогосподарських рослин зібрати достатню кількість промаркованих зображень (сотні тисяч екземплярів) неможливо враховуючи вплив навколишнього середовища, оптичних оклюзій і ілюзій, відмінність в умовах вирощування рослин і їх початкового зараження.

Передавальне навчання, яке зосереджується на передачі знань між доменами, є перспективною методологією машинного навчання для вирішення вищевказаної проблеми. Концепція передавального навчання

спочатку може виникнути з психології освіти. Відповідно до узагальнюючої теорії переносу, запропонованої психологом Ч. Джадом, передавальне навчання є результатом узагальнення досвіду. Здійснити перехід з однієї ситуації в іншу можливо, якщо людина узагальнить свій досвід. Відповідно до цієї теорії, передумовою передачі є наявність зв'язку між двома навчальними видами діяльності. На практиці людина, яка навчилася грати на скрипці, може навчитися грати на фортепіано швидше за інших, оскільки і скрипка, і фортепіано є музичними інструментами і можуть мати деякі спільні знання. Натхненне здібностями людей передавати знання між доменами, передавальне навчання має на меті використовувати знання з пов'язаної області, називається вихідним доменом, щоб покращити ефективність навчання або звести до мінімуму кількість позначених прикладів, необхідних у цільовій області. Варто зазначити, що передані знання не завжди позитивно впливають на нові завдання. Якщо між доменами мало спільного, передача знань може бути невдалою. Крім того, схожість між доменами не завжди сприяє навчанню, тому що іноді подібність може вводити в оману. Наприклад, хоча іспанська та французька мають багато спільного одна з одною і обидві належать до романської групи мов, люди, які вивчають іспанську мову, можуть відчувати труднощі у вивченні французької мови, наприклад, через використання неправильного словникового запасу або відмінювання. Це відбувається тому, що попередній успішний досвід іспанської мови може перешкоджати вивченню словотворення, вживання, вимови, відмінювання тощо французькою мовою. У галузі психології явище, що попередній досвід негативно впливає на засвоєння нових завдань, називається негативним перенесенням. [71]

Аналогічно, в області передавального навчання, якщо на цільового учня негативний вплив передані знання, це явище також називають негативним перенесенням. Чи відбудеться негативна передача, може залежати від кількох факторів, таких як релевантність між вихідним і цільовим



доменами, а також здатність учнів знаходити передачу та корисну частину знань у різних областях. [71]

Визначення передавального навчання надається в термінах доменів і завдань. Домен  $D$  складається з простору ознак  $X'$  та розподілу граничної ймовірності

$$P(X), X = \{x_1, \dots, x_n\} \in X' \quad (2.7)$$

та описується формулою

$$D = \{X', P(X)\}. \quad (2.8)$$

Візьмемо конкретний домен, завдання складається з двох компонентів: простору міток  $Y$  і цільової функції

$$f : X' \rightarrow Y. \quad (2.9)$$

Функція  $f$  використовується для передбачення відповідної мітки  $f(x)$  нового екземпляра  $x$ . [72] Це завдання, позначене

$$T = \{Y, f(x)\}, \quad (2.10)$$

вивчається з навчальних даних, що складаються з пар  $\{x_i, y_i\}$ , де  $x_i \in X$  та  $y_i \in Y$ . [72]

Дано вхідний домен  $D_s$  та завдання  $T_s$ , цільовий домен  $D_t$  та завдання  $T_t$ , де  $D_s \neq D_t$  або  $T_s \neq T_t$ , передавальне навчання має на меті допомогти покращити вивчення цільової функції  $f_t(\cdot)$  в  $D_t$  використовуючи знання з  $D_s$  та  $T_s$ . [72]

Згідно з розбіжністю між доменами, передавальне навчання можна далі розділити на дві категорії: однорідне та гетерогенне. [73] Розроблені та запропоновані однорідні підходи до навчання з перенесенням для обробки ситуацій, коли домени належать до одного простору ознак. При однорідному передавальному навчанні деякі дослідження припускають, що домени відрізняються лише граничними розподілами. [73] Тому вони адаптують домени, виправляючи зміщення вибірки або коваріантний зсув. Однак у багатьох випадках це припущення не виконується. Наприклад, у

задачі класифікації емоційного забарвлення слова може мати різні тенденції значення в різних областях. Це явище також називають упередженням ознак контексту. Щоб вирішити цю проблему, деякі дослідження додатково адаптують умовні розподіли. Гетерогенне навчання передачі відноситься до процесу передачі знань у ситуаціях, коли домени мають різні простори ознак. На додаток до адаптації розподілу, навчання гетерогенної передачі вимагає адаптації простору функцій, що робить його більш складним, ніж навчання однорідного перенесення. [74]

Передавальне навчання набирає все більшої популярності для вирішення проблем машинного навчання, коли в наборі даних недостатня кількість екземплярів через що використання класичних методів глибинного навчання є недоречним і не приносить жодних корисних результатів. Передавальне навчання своєрідним витвором машинного мистецтва (state-of-the-art) для класифікації рослин та застосовується повсюдно на різних наборах даних їх хвороб, шкідників, тощо. Детальніше про застосування концептів навчання описано в розділі 3.3.

## 2.5 Висновки до розділу

В другому розділі було детально розглянуто основні концепції та методи застосування гібридних експертних систем, що використовують нейронні мережі; основи і задачі нейронних мереж; структуру і застосування сегментаційних мереж; концепції передавального навчання. Обґрунтовано технології і архітектури, що будуть застосовані для практичної частини дослідження. Детально розібрані їх переваги та проблеми, уточнені можливі шляхи для подолання труднощів, що можуть з'явитися під час проведення наукових експериментів.

## 3 ОПИС ПРАКТИЧНОЇ ЧАСТИНИ ДОСЛІДЖЕННЯ

### 3.1 Розширення набору даних за допомогою лінійних трансформацій, накладанням оптичних ефектів, накладанням шкідників

Під час аналізу попередніх наукових досліджень щодо вирішення проблеми ідентифікації хвороби рослин за її ураженням листям було з'ясовано наступні проблеми набору даних: невелика кількість екземплярів зображень кожної з хвороби; продуктивність виявлення під впливом освітлення та оклюзії. Для тренування моделей глибокого навчання декілька сотень чи тисячі зображень – дуже невелика кількість, оскільки навчання потребує десятки, а то і сотні тисяч зразків для реалізації тої точності, що надає ця технологія машинного навчання. Проблема освітлення та оклюзії виявляється дещо складнішою і не може бути вирішена лише лінійними трансформаціями зображень під час процесу збільшення набору даних.

Для розв'язання проблем попередніх досліджень було прийнято рішення проводити дослідження лише з поширеними в Україні сільськогосподарськими рослинами, а саме: томат та картопля. Це дасть змогу більш точно відслідкувати нові проблеми, що будуть виникати з побудовою моделей та більш гнучко приймати рішення щодо їх покращень. Також було проведено декілька експериментів з використанням класів лише хвороби рослин без уточнення які саме це рослини, наприклад, класи “томат з ознаками бактеріальної хвороби” та “картопля з ознаками бактеріальної хвороби” стали “рослина з ознаками бактеріальної хвороби”.

Нагадаємо, що в роботі використано частково датасет компанії PlantVillage, яка займається розробками в сферах штучного інтелекту та зібрала десятки тисяч зображень хворих рослин. [75] Всього набір даних містить 38 класів та 65 тисяч зображень. З них було використано 8 класів, що містять томати та картоплю: «ранній фітофтороз картоплі», «здорова

картопля», «пізній фітофтороз картоплі», «томат з бактеріальною плямою», «ранній фітофтороз томату», «здоровий томат», «пізній фітофтороз томату», та «цвіль листя томату».




Рисунок 3.1 – Розподіл класів, набір даних незбалансований

Для роботи з набором даних та його розширенням було використано програмний код/мікрофреймворк з попереднього дослідження за допомогою якого можна швидко працювати з датасетами різних рослин і хворобами; додавати нові набори даних; розробляти і навчати нові архітектури глибоких нейронних мереж із застосуванням різних технологій і нових методів та практик.




Рисунок 3.2 – Приклад зображень класу «томат з бактеріальною плямою»

Розширення і балансування класів набору даних відбувалося в три етапи: трансформації за допомогою випадкових лінійних перетворень (вирізання області, зміна розміру, поворот, довільна афінне перетворення, горизонтальний та вертикальний перевероти, оптична перспектива), накладання складних візуальних ефектів (сонячний відблиск, туман, RGB зсув, сніг, грубе відсівання, сильна JPEG компресія, накладання шуму та розмиття по Гаусу), додавання шкідників на зображення листя.

Випадкові лінійні перетворення було застосовано за допомогою засобів бібліотеки pyTorch і доступних методів й функцій звідти. [76]

```
def torch_transforms():  
    return [  
        transforms.RandomRotation(45),  
        transforms.RandomAffine(35),  
        transforms.RandomCrop(128),  
        transforms.RandomHorizontalFlip(p=1),  
        transforms.RandomPerspective(p=1),  
        transforms.RandomVerticalFlip(p=1),  
        transforms.GaussianBlur(kernel_size=(5, 9), sigma=(0.1, 5)),  
        transforms.RandomAdjustSharpness(sharpness_factor=2, p=0.5),  
    ]
```

Рисунок 3.3 – Фрагмент коду для розширення набору даних за допомогою лінійних перетворень

В додатку А наведено приклади зображення із застосуванням лінійних перетворень.

```
def albumentation():
    return [
        A.RandomSunFlare(p=1, src_radius=70),
        A.RandomFog(p=1, fog_coef_lower=0.8),
        A.RandomBrightness(p=1),
        A.RandomCrop(p=1, height=180, width=180),
        A.Rotate(p=1, limit=90),
        A.RGBShift(p=1),
        A.RandomSnow(p=1),
        A.HorizontalFlip(p=1),
        A.VerticalFlip(p=1),
        A.RandomContrast(limit=0.5, p=1),
        A.HueSaturationValue(
            p=1, hue_shift_limit=20, sat_shift_limit=30, val_shift_limit=50
        ),
        A.Cutout(p=1),
        A.Transpose(p=1),
        A.JpegCompression(p=1),
        A.CoarseDropout(p=1),
        A.IAAAdditiveGaussianNoise(
            loc=0, scale=(2.5500000000000003, 12.75), per_channel=False, p=1
        ),
        A.IAAAffine(
            scale=1.0, translate_percent=None,
            translate_px=None, rotate=0.0,
            shear=0.0, order=1, cval=0,
            mode='reflect', p=1
        ),
        A.Affine(rotate=90., p=1),
        A.Affine(rotate=180., p=1)
    ]
```

Рисунок 3.4 – Фрагмент коду для додавання візуальних ефектів

В додатку Б наведено приклади накладання різних візуальних ефектів.

Для додавання шкідників було використано звичайне зображення бджілки. Його накладено в різних місцях зображення для зменшення вірогідності моделі перенавчатися, відповідно збільшується її точність та можливість працювати в різних умовах навіть з такими перешкодами. Функціональність легко розширюється новими зображеннями шкідників та їх комбінаціями. Також було додано можливість накладати лише фігуру шкідників з довільним темним кольором для імітації тіні таких комах.




Рисунок 3.5 – Приклад накладання шкідників: звичайний кольоровий варіант та темний варіант – імітація тіні

За допомогою таких розширень набір даних тепер збалансований та містить близько 5 тисяч екземплярів на кожен клас зображень. Такі перетворення мають вирішити проблему недостатнього об'єму тренувальних та валідаційних даних, підвищити продуктивність моделей під впливом освітлення, оклюзій, зміни зовнішнього середовища.

Було окремо зібрано тестовий набір даних різних листків з різним фоном, різними навколишніми умовами, що налічує приблизно 5-7 зображень кожного класу. Для цього було використано електронну енциклопедію рослин [ecosia.org](http://ecosia.org), [77] а також інші зображення з відкритого доступу університетів США, Австралії та Канади.

### 3.2 Розробка сегментаційної моделі

На практиці сегментація польових зображень листя за допомогою звичайних методів, таких як порогове визначення, групування, виявлення країв тощо, є неефективною через складний вигляд листя та різноманітність фону, а також умов освітлення. Кращий варіант передбачає використання сучасних методів сегментації з наглядом на основі глибинного навчання або слабо контрольованих методів сегментації. Однак перший підхід зазвичай вимагає наборів даних анотацій на рівні пікселів, щоб отримати надійний результат, і тому є трудомістким. Останній підхід витягує інформацію про

сегментацію з карт ознак, створених глибинною мережею, навченою для класифікації зображень. Хоч у таких слабо контрольованих моделей є перевага в тому, що їх можна навчити без додаткових даних маркування, моделі часто є складними і вимагають трудомістку реалізацію.

У цій роботі запропоновано простий, але ефективний слабо контрольований модуль сегментації листя без міток, який допомагає моделі класифікації неявно вивчати щільні та внутрішні ділянки листя. З точки зору архітектури, основою цієї моделі є CNN, яка розроблена для розрізнення класів «повний лист», «частковий лист» і «без листка». Зокрема, об'єкти класу «повний лист» – це зображення, які містять зображення одного повного листка рослини, а об'єкти класу «частковий лист» – це зображення, які містять частину листка рослини, тоді як об'єкти «без листка» не містять жодної частини листя рослин.

Сегментована область листка отримана за допомогою теплової карти класу «повний лист» за допомогою методики Grad-CAM. [78] Ця тепла карта є картою ймовірностей, що представляє вірогідність кожного пікселя потрапити в остаточне рішення класу «повний лист», і, таким чином, може використовуватися як бінарна маска з певним пороговим значенням  $\delta$ .

Ключова ідея, що лежить в основі моделі сегментації – це введення класу «частковий лист» для навчання. Теплова карта класифікатора, яка навчена розрізняти об'єкт та його фон, охоплюватиме лише невеликі та найбільш вірогідні області шуканого об'єкта. Тому, якщо навчати модель тільки для класифікації об'єктів класів «повний лист» і «без листка», мережа не зможе охопити повністю область об'єкта класу «повний лист». Від так, модель не буде виконувати заплановану роль сегментації. Введення класу «частковий лист» використовується моделлю для пошуку більшої області у формі листка, щоб правильно класифікувати зображення класу «повний лист».






Рисунок 3.6 – Теплові карти передбачення сегментаційної мережі

На рисунку 3.6 показано порівняння теплових карт між моделями класифікації з навчальними даними «часткового листка» та без них. Чим тепліший колір регіону, тим більше він сприяє остаточному вирішенню для класу «повний лист». Ці теплові карти показують, що навчена мережа за стратегією, описаною вище, здатна зосередитися на всій формі зображень «повний лист», тоді як інша модель без класу «часткового листа» (тобто, яка класифікує лише зображення «повний лист» та «без листка») фокусується на невеликих, розсіяних ділянках листя рослин.

Модель сегментації досягла показника F1 в 98,1% для сегментації листя томатів та картоплі, використовуючи лише близько 8000 замаскованих зображень для навчання. В додатку В наведено приклади виконання передбачень для різних класів в режимі генерації теплової карти.




Рисунок 3.7 – Приклад передбачення моделі сегментації (з використанням маскування або теплової карти)

```
# Load the LeafSeg module (ResNet101 backbone)
seg_model = models.resnet101()
num_fts = seg_model.fc.in_features
# Replace final layer with 3 outputs (full leaf, partial leaf, non-leaf)
seg_model.fc = nn.Linear(num_fts, 3)

load_path = './LeafSeg_resnet101.pth'
seg_model.load_state_dict(torch.load(load_path), strict=True)

seg_model.to(device)
seg_model.eval()

# Load the GradCAM function
gcam = GradCAM(model=seg_model)
```

Рисунок 3.8 – Фрагмент коду для виклику передбачення мережі сегментації

### 3.3 Навчання моделі із застосуванням передавального навчання

Передавальне навчання було використано для однієї з останніх моделей машинного навчання, а саме EfficientNetB7. Остання оновлена версія мереж серії EfficientNet, які стали основою для всього передавального навчання останні декілька років. Ця модель досягла найсучаснішої (state-of-the-art) точності на CIFAR-100 (91.7%) та Flowers (98.7%) та 3 інших наборах даних навчання, маючи на порядок меншу кількість параметрів для навчання. [79]




Рисунок 3.9 – Розмір моделі в порівнянні з точністю на датасеті ImageNet.

Усі номери для одного зрізу, однієї моделі. EfficientNets значно перевершують інші мережі ConvNets. Зокрема, EfficientNet-B7 досягає нової найсучаснішої точності 84,3% топ-1, але будучи в 8,4 рази меншим і в 6,1 рази швидше, ніж GPipe. EfficientNet-B1 в 7,6 рази менший і в 5,7 рази швидше, ніж ResNet-152 [79]

На сьогодні моделі, навчені за допомогою використання передавального навчання, і саме цієї родини від розробників фреймворку tensorflow займають перші місця на змаганнях агропромислового сектору технологій комп'ютерного зору. Також активно зростає відсоток їх застосування в комерційних продуктах передавального навчання, комп'ютерного зору, використання в промисловості. Результати дослідження показали, що модель дуже точно виконує класифікацію загальних об'єктів і текстур. Проте, під час навчання мережі для розпізнавання хвороби рослин, архітектура втрачає точність на класах, що мають багато подібностей, наприклад, «фітофтороз картоплі» та «фітофтороз томату».

Для навчання було використано алгоритм оптимізації Адам, модифікована версія стохастичного градієнта. Обрано функцією втрат – перехресну ентропію, яка вираховується за формулою

$$Loss = -y * \log(y') - (1 - y) * \log(1 - y'). \quad (3.1)$$



Рисунок 3.10 – Тестове зображення та передбачення моделі з правильною класифікацією хвороби і неправильним класом рослини. В лівому верхньому кутку: зелений напис – справжній клас зображення, червоний – передбачення навченої мережі

При правильній класифікації хвороби, модель втратила точність в класифікації самої рослини, що не є катастрофічним, але залишається неточністю. З такої самої причини, трапляється неточність з класифікацією точної хвороби. Тому проблема тонкої класифікації, що була детально окреслена в першому розділі, все ще не вирішена до кінця, але не можна не зазначити значний успіх в підвищенні точності для ідентифікації таких тонких і схожих структур на зображеннях листя рослин.



Рисунок 3.11 – Тестове зображення та передбачення моделі схожого класу хвороби. В лівому верхньому кутку: зелений напис – справжній клас зображення, червоний – передбачення навченої мережі

```
def build_model(pretrained=True, fine_tune=True, num_classes=10):
    if pretrained:
        print('[INFO]: Loading pre-trained weights')
    else:
        print('[INFO]: Not loading pre-trained weights')
    model = models.efficientnet_b7(pretrained=pretrained)

    if fine_tune:
        print('[INFO]: Fine-tuning all layers...')
        for params in model.parameters():
            params.requires_grad = True
    elif not fine_tune:
        print('[INFO]: Freezing hidden layers...')
        for params in model.parameters():
            params.requires_grad = False

    # Change the final classification head.
    model.classifier[1] = nn.Linear(
        in_features=model.classifier[1].in_features, out_features=num_classes, bias=True
    )
    return model
```

Рисунок 3.12 – Фрагмент коду для навчання моделі EfficientB7 із використанням технологій передавального навчання




Рисунок 3.13 – Приклади тестових передбачень. В лівому верхньому кутку: зелений напис – справжній клас зображення, червоний – передбачення навченої мережі

Модель досягла точності 97.6% на тренувальних даних, 96.8% на валідаційних та близько 60% на тестових.

### 3.4 Використання хмарного сервісу AWS для навчання

Для проведення наукових експериментів було використано хмархи сервіс AWS SageMaker, який дозволяє легко і швидко створювати нові роботи навчання, використовуючи хмарні ресурси AWS. Для навчання лише достатньо загрузити набір даних на власну корзину AWS S3 сховища: це

можна зробити вручну використовуючи термінал комп'ютера та AWS CLI бібліотеку, яка розширює команди терміналу, або використовуючи графічний інтерфейс веб-сервісу.



| Name                                                | Creation time          | Duration  | Status    |
|-----------------------------------------------------|------------------------|-----------|-----------|
| pytorch-training-2022-06-11-19-47-01-616            | Jun 11, 2022 19:47 UTC | 21 hours  | Completed |
| pytorch-training-2022-06-11-06-24                   | Jun 11, 2022 06:32 UTC | 6 minutes | Failed    |
| pytorch-training-2022-06-10-11-19-26-709-copy-06-10 | Jun 10, 2022 13:09 UTC | 17 hours  | Stopped   |
| pytorch-training-2022-06-10-11-19-26-709            | Jun 10, 2022 11:19 UTC | an hour   | Failed    |
| pytorch-training-2022-06-10-11-10-20-546            | Jun 10, 2022 11:10 UTC | 6 minutes | Failed    |
| pytorch-training-2022-06-10-11-02-34-834            | Jun 10, 2022 11:02 UTC | 6 minutes | Failed    |

Рисунок 3.14 – Список поточних/виконаних/невдалих запусків навчання моделей в хмарному сервісі AWS SageMaker

SageMaker дуже простий у використанні: для запуску можна використовувати власний код моделі для тренування нейронних мереж. Під час проведення дослідження, використано напрацьований програмний інтерфейс попереднього дослідження, легко розширено поточними моделями сегментації та передавального навчання. Для коректного навчання та регулюванню гіперпараметрів моделей необхідно обробляти змінні середовища, а також використовувати їх для збереження додаткових даних навчання (таких як дані для графіків зміни точності, функції втрат, валідації, тощо під час навчання) та самої моделі.

Після навчання хмарний сервіс робить автоматичний звіт, за який можна покращити результати навчання. В ньому можна знайти поради щодо оптимізації гіперпараметрів моделі, а також поради про оптимізацію використаних ресурсів таких як використання процесора, відеокарти чи дискового простору.



### Rules summary

The following table shows a profiling summary of the Debugger built-in rules. The table is sorted by the rules that triggered the most frequently. During your training job, the IOBottleneck rule was the most frequently triggered. It processed 307047 datapoints and was triggered 0 times.

|                              | Description                                                                                                                                                                                                                                                                                                                                                                     | Recommendation                                                                                                                 | Number of times rule triggered | Number of datapoints | Rule parameters                                                      |
|------------------------------|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|--------------------------------------------------------------------------------------------------------------------------------|--------------------------------|----------------------|----------------------------------------------------------------------|
| <b>IOBottleneck</b>          | Checks if the data I/O wait time is high and the GPU utilization is low. It might indicate IO bottlenecks where GPU is waiting for data to arrive from storage. The rule evaluates the I/O and GPU utilization rates and triggers the issue if the time spent on the IO bottleneck exceeds a threshold percent of the total training time. The default threshold is 50 percent. | Pre-fetch data or choose different file formats, such as binary formats that improve I/O performance.                          | 0                              | 307047               | threshold:50<br>io_threshold:50<br>gpu_threshold:10<br>patience:1000 |
| <b>MaxInitializationTime</b> | Checks if the time spent on initialization exceeds a threshold percent of the total training time. The rule waits until the first step of training loop starts. The initialization can take longer if downloading the entire dataset from Amazon S3 in File mode. The default threshold is 20 minutes.                                                                          | Initialization takes too long. If using File mode, consider switching to Pipe mode in case you are using TensorFlow framework. | 0                              | 0                    | threshold:20                                                         |
| <b>LowGPUUtilization</b>     | Checks if the GPU utilization is low or fluctuating. This can happen due to bottlenecks, blocking calls for synchronizations, or a small batch size.                                                                                                                                                                                                                            | Check if there are bottlenecks, minimize blocking calls, change distributed training strategy, or increase the batch size.     | 0                              | 0                    | threshold_p95:70<br>threshold_p5:10<br>window:500<br>patience:1000   |
| <b>GPUMemoryIncrease</b>     | Measures the average GPU memory footprint and triggers if there is a large increase.                                                                                                                                                                                                                                                                                            | Choose a larger instance type with more memory if footprint is close to maximum available memory.                              | 0                              | 0                    | increase:5<br>patience:1000<br>window:10                             |
| <b>Dataloader</b>            | Checks how many data loaders are running in parallel and whether the total number is equal to the number of available CPU cores. The rule triggers if number is much smaller or larger than the number of available cores. If too small, it might lead to low GPU utilization. If too large, it might impact other compute intensive operations on CPU.                         | Change the number of data loader processes.                                                                                    | 0                              | 0                    | min_threshold:70<br>max_threshold:200                                |

Рисунок 3.15 – Фрагмент звіту з порадами, що було створено після проведення навчання

Хмарний сервіс надає всі інструменти для моніторингу, запуску навчання, регулюванню та покращенню значень гіперпараметрів моделей, швидкий і зручний перегляд журналу логів, інших метрик.




Рисунок 3.16 – Користувацький інтерфейс для перегляду графіків роботи машини, яка виконувала завдання, її метрик та журналів логів

Також AWS SageMaker дозволяє одразу розгорнути модель в хмарному сервісі і вона швидко стане доступна за відповідним URL'ом.

```
def model_fn(model_dir):
    logger.info("model_fn")
    device = "cuda" if torch.cuda.is_available() else "cpu"
    model = build_model()
    if torch.cuda.device_count() > 1:
        logger.info("Gpu count: {}".format(torch.cuda.device_count()))
        model = nn.DataParallel(model)

    with open(os.path.join(model_dir, "model.pth"), "rb") as f:
        model.load_state_dict(torch.load(f))
    return model.to(device)
```

Рисунок 3.17 – Приклад функції, що створює модель для передбачення, використовується під час розгортання моделі

### 3.5 Результати дослідження та їх порівняння

Результати сегментаційної моделі. Мережа досягла дуже високої точності, оскільки мала збалансований набір даних (~10000 зображень на кожен з трьох класів) та достатню трансформацію зображень для навчання. Модель досягнула точності в 99.7% на валідаційних даних та значення F1 в 98.1%. Точність на тестових склала 81.2%. В додатку В наведено приклади тестової роботи сегментаційної мережі у режимі створення теплової карти цільової області на різних зображеннях. Для навчання класифікаційної моделі використовувалися вихідні зображення сегментаційного модуля в режимі маски, тобто пікселі, що не належать шуканій області замальовувалися чорним кольором.

EfficientNetB7 класифікаційна мережа навчена за допомогою методу передавального навчання. Модель досягла точності 97.6% на тренувальних даних, 96.8% на валідаційних та близько 60% на тестових. Варто підкреслити, що на тестових даних передбачення рослини томату (без хвороби) мало точність 91%, для картоплі – 73%. Такий дисбаланс виник через перевищення в наборі даних класів з томатами 5 проти 3 класів з картоплею. По хворобам також присутній дисбаланс, тому що моделі вдалося завчити більш візуально чітку форму фітофторозу, ніж більш складно впізнавані бактеріальні чи листовий цвіль. На тестових даних вдалося досягнути 97% точності визначення фітофторозу та приблизно в



межах 30-40% для бактеріальної плям та цвілі. Після такого аналізу було виявлено нові проблеми та втрату точності на тестових даних, тому прийнято рішення створити окремі набори даних лише з класами рослин, згрупованими хворобами та зі збалансованою кількістю класів хворіб для кожної з рослин.

Тому були додатково проведені такі дослідження: 2 класи томатів проти 2 класів картоплі (класи: «здорове листя», «фітофтороз»), поєднання окремо навчених моделей класів рослин та хвороб. Такі комбінації класів моделей не дали високого приросту точності. Мережі все ще перенавчаються різні зовнішні умови, різну нестандартну форму листя, недостатність вхідних даних, різний час фіксації експерименту (створення зображення ураженого листя). Під час застосування двох окремих моделей для класифікації рослин та хворіб відповідно середній час передбачення класифікаційного модуля сильно виріс з 250 до 750 мс, а потрібна кількість ОЗП для програми збільшилася в 2.4 рази.

Згорткові моделі, які були найточнішими в попередньому дослідженні, також були додані у варіанти експертних систем. Для цього вони були натреновані з сегментаційним модулем та розширеним набором даних за допомогою методів описаних у пункті 3.1. Вони досягли точності приблизно в 93% на тренувальних даних та 88% на валідаційних. Відповідно до поставлених задач перевірка також була здійснена на тестових даних, спеціально відібраному наборі для польових умов. На ньому згорткові мережі суттєво втратили точність та стали неефективними, правильними результатами були лише до 40% передбачень.

Варто зазначити, що також проводилися експерименти без використання сегментаційного модуля експертної системи. Хоча на тестових даних мережа втратила достатньо точності (до 81%) її вимкнення з програми сильно вплинуло на точність класифікаційних моделей. В середньому падіння точності для моделей передавального навчання було в

межах 15-20% і передбачення вже не мали сенсу (менш ніж 40% правильних результатів). Для згорткових моделей, найкращі з попереднього дослідження, падіння було до 10-12% істинних значень в середньому.

На таблиці 3.1 нижче наведено зведені результати точності всіх проведених експериментів.

Таблиця 3.1 – Порівняння результатів точності моделей проведених експериментів (рядки – назви проведених експериментів, колонки – назви моделей, жирним – виділено найкращі результати серед моделей в одному експерименті)

|                                                           | EfficientB7 | EfficientB7<br>(2 класи:<br>здорові та<br>хворі) | EfficientB7<br>(окремо моделі<br>для рослин та<br>хвороб) | AlexNet | EasyNet |
|-----------------------------------------------------------|-------------|--------------------------------------------------|-----------------------------------------------------------|---------|---------|
| Точність на<br>тренувальних<br>даних (без<br>сегментації) | 95.4%       | <b>96.7%</b>                                     | 96.3%                                                     | 92.8%   | 93.8%   |
| Точність на<br>тестових даних<br>(без сегментації)        | 32.8%       | 39.4%                                            | <b>43.5%</b>                                              | 12%     | 10%     |
| Точність на<br>тренувальних<br>даних (з<br>сегментації)   | 97.6%       | <b>99.1%</b>                                     | 98.9%                                                     | 93%     | 92.1%   |
| Точність на<br>тестових даних (з<br>сегментації)          | 60%         | 60.3%                                            | <b>61.2%</b>                                              | 34%     | 17%     |

Після проведених експериментів необхідно підкреслити значущість вхідних даних для моделей машинного навчання. Їх якість та чистота є

одними з найголовніших поставлених задач наукового дослідження чи вимог бізнесу. Набір даних з різноманітними обертами листя в просторі зображення, постійні згини листя по його периметру чи листя з плямою вигоряння на сонці стають непереборною перешкодою навіть для найкращих моделей класифікації рослин з високоточним модулем сегментації та максимально розширеним датасетом трансформаціями і візуальними ефектами. Описані вище особливості, що не пов'язані безпосередньо з хворобами, стають спільними ознаками між різними класами мережі. Такі спільні ознаки чітко видно під час валідації моделі і візуалізації її карти ознак під час прогонів тестових зображень. Для подолання цієї проблеми гігант української агропромисловості Kernel дуже чітко фіксує правила інформативності отриманого зображення під час оцінки врожайності та густоти посіву. Керівник відділу штучного інтелекту компанії у своїй статі зазначив, що агрономи мають фотографувати свої поля тільки на певній відстані від землі, в спеціально відведені дні після посіву, а також мають забезпечити чистоту від бур'яну та інших сторонніх предметів. [80] Створення таких складних умов потребує дуже трудомісткого процесу збору тренувальних даних, обробка яких може тривати роками командами науковців. Для малого та середнього фермерства це взагалі неможливо здійснити через громіздкі вимоги до формату зображень, їх інформативності та інших метаданих, які складно занотувати. Інший варіант як обійти проблему чистоти набору даних – створити багатомільйонний датасет на зразок ImageNet тільки для здорових та хворих рослин сільськогосподарських культур із перевіреними зображеннями і мітками класів експертами-біологами.

## Висновки

Результатом дипломної роботи стало дослідження та створення гібридної експертної системи з використанням нейронних мереж для розпізнавання хвороби сільськогосподарських рослин. Для системи окремо було розроблено сегментаційний та класифікаційний модулі. Запропоновано метод розширення даних для проблем класифікації хворіб рослин з використанням лінійних трансформацій та спеціальних візуальних ефектів. Експерименти проводилися для томатів та картоплі, з таким набором хворіб рослин: ранній та пізній фітофтороз, бактеріальна хвороба, цвіль листя. Сегментаційний модуль системи досягнув точності в 99.7% на тренувальних даних, 81.2% на тестових. Класифікаційний модуль досягнув точності в 97.6% на тренувальних даних та близько 60% на тестових. Результати були ґрунтовно проаналізовані, запропоновано можливі шляхи вирішення для нових проблем. Детальніше в розділі 3.5.

Під час проведення наукового дослідження було детально проаналізовано роботи науковців щодо застосування технологій машинного навчання для визначення хвороби рослин за її ураженням листям. З'ясовані переваги, недоліки, проблеми та результати попередніх наукових робіт. Завдяки такому розширеному аналізу було узагальнено проблеми, які зараз утворюють перепони для остаточного вирішення задачі ідентифікації хвороби сільськогосподарських рослин.

Будо детально вивчено сучасні методи гібридних експертних систем, їх застосування з нейронними мережами. Досліджено технології машинного навчання для сегментації та класифікації зображень. Розібрано та використано передавальне навчання як один з найсучасніших засобів тренування моделей з попередньо підготовленими параметрами.

У третьому розділі роботи детально описано етап проектування гібридної експертної системи, процеси підготовки даних, навчання

використаних нейронних мереж. Розібрано переваги і недоліки розробленої системи, проаналізовано результати, чітко сформовано нові труднощі, що з'явилися під час тестування моделей, описано можливі шляхи їх подолання для подальшого удосконалення системи.

Результати тестових прогонів розроблених моделей були також порівнянні з результатами нейронних мереж з попереднього дослідження. Ці мережі значно втрачають у точності, а їх використання у польових умовах стає марним. Детальне порівняння описано у розділі 3.5.

Для проведення наукових експериментів, підготовки та розширення набору даних, навчання модулів системи і нейронних мереж було використано програмний інтерфейс з попереднього дослідження, спеціально розроблений для застосування комп'ютерного зору в агропромислових рішеннях. Він дозволяє швидко інтегрувати нові архітектури моделей машинного навчання, створювати звіти щодо процесу навчання, спрощує подальшу роботу з передбаченнями. Для передбачень гібридної експертної системи в польових умовах було застосовано програмний код чат-боту з попередньої роботи, що дозволяє користувачам надсилати зображення ураженого листа рослин та отримувати корисну інформацію про хворобу та способи лікування.

В перспективі, гібридна експертна система може полегшити роботу сільськогосподарських підприємств та фермерів, що не мають достатньо коштів для найму відповідного персоналу для виявлення та аналізу хворіб рослин. Така система матиме високу точність ідентифікації конкретних хворіб та надаватиме вичерпну інформацію щодо їх лікування та профілактики.

### Список Використаної Літератури

1. Cai H. Nonculture molecular techniques for diagnosis of bacterial disease in animals a diagnostic laboratory perspective [Electronic resource] / H. Cai, J. Caswell, J. Prescott. – 2014 – Mode of access: <https://pubmed.ncbi.nlm.nih.gov/24569613/>.
2. Lopez M. Innovative tools for detection of plant pathogenic viruses and bacteria [Electronic resource] / M. Lopez, E. Bertolini, et al. – 2003 – Mode of access: <https://pubmed.ncbi.nlm.nih.gov/13680391/>.
3. Kempf V. Fluorescent in situ hybridization allows rapid identification of microorganisms in blood cultures [Electronic resource] / V. Kempf, K. Trebesius, I. Autenrieth, et al. – 2000 – Mode of access: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC86216/>.
4. Moter A. Fluorescence in situ hybridization (FISH) for direct visualization of microorganisms [Electronic resource] / A. Moter, U. Göbel. – 2000 – Mode of access: <https://pubmed.ncbi.nlm.nih.gov/10991623/>.
5. Clark M. Characteristics of the microplate method of enzyme-linked immunosorbent assay for the detection of plant viruses [Electronic resource] / M. Clark, A. Adams, J. Gen. – 1977 – Mode of access: <https://pubmed.ncbi.nlm.nih.gov/323416/>.
6. Lopez M. Strategies for improving serological and molecular detection of plant pathogenic bacteria [Electronic resource] / M. Lopez, et al. – 2001 – Mode of access: [https://link.springer.com/chapter/10.1007/978-94-010-0003-1\\_15](https://link.springer.com/chapter/10.1007/978-94-010-0003-1_15).
7. Wullings B. Detection of *Ralstonia solanacearum*, which causes brown rot of potato, by fluorescent in situ hybridization with 23S rRNA-targeted probes [Electronic resource] / B. Wullings, et al. – 1998 – Mode of access: <https://pubmed.ncbi.nlm.nih.gov/9797321/>.
8. Chitarra L. The application of flow cytometry and fluorescent probe technology for detection and assessment of viability of plant pathogenic bacteria [Electronic resource] / L. Chitarra, R. van den Bulk, J. Eur. – 2003 – Mode of access: [https://www.researchgate.net/publication/226278648\\_The\\_Application\\_of\\_Flow\\_Cytometry\\_and\\_Fluorescent\\_Probe\\_Technology\\_for\\_Detection\\_and\\_Assessment\\_of\\_Viability\\_of\\_Plant\\_Pathogenic\\_Bacteria](https://www.researchgate.net/publication/226278648_The_Application_of_Flow_Cytometry_and_Fluorescent_Probe_Technology_for_Detection_and_Assessment_of_Viability_of_Plant_Pathogenic_Bacteria).
9. Diaper J. Flow cytometric detection of viable bacteria in compost [Electronic resource] / J. Diaper, C. Edwards. – 1994 – Mode of access: <https://www.sciencedirect.com/science/article/abs/pii/0168649694900035>.

10. Chaerle L. Imaging techniques and the early detection of plant stress [Electronic resource] / L. Chaerle, D. van der Straeten. – 2000 – Mode of access: <https://pubmed.ncbi.nlm.nih.gov/11077259/>.

11. Oerke E. Thermal imaging of cucumber leaves affected by downy mildew and environmental conditions [Electronic resource] / E. Oerker, et al. – 2006 – <https://pubmed.ncbi.nlm.nih.gov/16714311/>.

12. Hillnhütter C. Remote sensing to detect plant stress induced by *Heterodera schachtii* and *Rhizoctonia solani* in sugar beet fields [Electronic resource] / C. Hillnhütter, et al. – 2011 – Mode of access: <https://www.sciencedirect.com/science/article/abs/pii/S0378429011000566>.

13. Kuckenberg J. Temporal and spatial changes of chlorophyll fluorescence as a basis for early and precise detection of leaf rust and powdery mildew infections in wheat leaves [Electronic resource] / J. Kuckenberg, I. Tartachnyk, G. Noga. – 2009 – Mode of access: [https://www.researchgate.net/publication/227250788\\_Temporal\\_and\\_spatial\\_changes\\_of\\_chlorophyll\\_fluorescence\\_as\\_a\\_basis\\_for\\_early\\_and\\_precise\\_detection\\_of\\_leaf\\_rust\\_and\\_powdery\\_mildew\\_infections\\_in\\_wheat\\_leaves](https://www.researchgate.net/publication/227250788_Temporal_and_spatial_changes_of_chlorophyll_fluorescence_as_a_basis_for_early_and_precise_detection_of_leaf_rust_and_powdery_mildew_infections_in_wheat_leaves).

14. Delalieux S. Detection of biotic stress (*Venturia inaequalis*) in apple trees using hyperspectral data: Non-parametric statistical approaches and physiological implications [Electronic resource] / S. Delalieux, et al. – 2007 – Mode of access: <https://www.sciencedirect.com/science/article/abs/pii/S1161030107000287>.

15. Kobayashi T. Detection of rice panicle blast with multispectral radiometer and the potential of using airborne multispectral scanners [Electronic resource] / T. Kobayashi, et al. – 2001 – Mode of access: <https://pubmed.ncbi.nlm.nih.gov/18943352/>.

16. Fang Y. Electrochemical detection of p-ethylguaiacol, a fungi infected fruit volatile using metal oxide nanoparticles [Electronic resource] / Y. Fang, Y. Umasankar, R. Ramasamy. – 2014 – Mode of access: <https://pubs.rsc.org/en/content/articlelanding/2014/an/c4an00384e>.

17. Kesselmeier J. Biogenic volatile organic compounds (VOC): An overview on emission, physiology and ecology [Electronic resource] / J. Kesselmeier, M. Staudt. – 1999 – Mode of access: <https://link.springer.com/article/10.1023/A:1006127516791>.

18. Shipway A. Nanoparticle arrays on surfaces for electronic, optical, and sensor applications [Electronic resource] / A. Shipway, E. Katz, J. Willner. – 2000 – Mode of access: <https://pubmed.ncbi.nlm.nih.gov/23696260/>.

19. Lopez M. Are molecular tools solving the challenges posed by detection of plant pathogenic bacteria and viruses? [Electronic resource] / M. Lopez, et al. – 2009 – Mode of access: <https://pubmed.ncbi.nlm.nih.gov/18577779/>.

20. Ronkainen N. Electrochemical biosensors [Electronic resource] / N. Ronkainen, H. Halsall, W. Heineman. – 2010 – Mode of access: <https://pubs.rsc.org/en/content/articlelanding/2010/cs/b714449k>.

21. Mc Grath S. Genetics and Molecular Biology [Electronic resource] / S. Mc Grath, D. van Sinderen. – 2007 – Mode of access: <https://www.caister.com/phage>.

22. Schofield D. “Light-tagged” bacteriophage as a diagnostic tool for the detection of phytopathogens [Electronic resource] / D. Schofield, et al. – 2013 – Mode of access: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC3566022/>.

23. Yalcin H. Plant classification using convolutional neural networks [Electronic resource] / H. Yalcin, S. Razavi. – 2016 – Mode of access: <https://www.semanticscholar.org/paper/Plant-classification-using-convolutional-neural-Yalcin-Razavi/2830bc9a069cb27bf00cd4c26299ddc74caa3afc>.

24. Fuentes A. Anomaly detection of plant diseases and insects using convolutional neural networks [Electronic resource] A. Fuentes, et al. – 2017 – Mode of access: [https://www.researchgate.net/publication/322137872\\_Anomaly\\_Detection\\_of\\_Plant\\_Diseases\\_and\\_Insects\\_using\\_Convolutional\\_Neural\\_Networks](https://www.researchgate.net/publication/322137872_Anomaly_Detection_of_Plant_Diseases_and_Insects_using_Convolutional_Neural_Networks).

25. Hasan M. Rice disease identification and classification by integrating support vector machine with deep convolutional neural network [Electronic resource] / M. Hasan, et al. – 2019 – Mode of access: <https://ieeexplore.ieee.org/document/8934568>.

26. Thenmozhi K. Crop pest classification based on deep convolutional neural network and transfer learning [Electronic resource] K. Thenmozhi, U.



Reddy. – 2019 – Mode of access: <https://www.sciencedirect.com/science/article/abs/pii/S0168169919310695>.

27. Fang T. Crop leaf disease grade identification based on an improved convolutional neural network [Electronic resource] / T. Fang, et al. – 2020 – Mode of access: [https://www.researchgate.net/publication/338538300\\_Crop\\_leaf\\_disease\\_grade\\_identification\\_based\\_on\\_an\\_improved\\_convolutional\\_neural\\_network](https://www.researchgate.net/publication/338538300_Crop_leaf_disease_grade_identification_based_on_an_improved_convolutional_neural_network).

28. Nagasubramanian K. Plant disease identification using explainable 3D deep learning on hyperspectral images [Electronic resource] / K. Nagasubramanian, et al. – 2019 – Mode of access: <https://plantmethods.biomedcentral.com/articles/10.1186/s13007-019-0479-8>.

29. Tianjiao C. Intelligent identification system of disease and insect pests based on deep learning [Electronic resource] / C. Tianjiao, et al. – 2019 – Mode of access: <https://www.hindawi.com/journals/sp/2022/9179998/>.

30. Dechant C. Automated identification of northern leaf blight-infected maize plants from field imagery using deep learning [Electronic resource] / C. Dechant, et al. – 2017 – Mode of access: <https://pubmed.ncbi.nlm.nih.gov/28653579/>.

31. Wiesner-Hanks T. Millimeter-level plant disease detection from aerial photographs via deep learning and crowdsourced data [Electronic resource] / T. Wiesner-Hanks, et al. – 2019 – Mode of access: <https://www.frontiersin.org/articles/10.3389/fpls.2019.01550/full>.

32. Shougang R. Deconvolution-guided tomato leaf disease identification and lesion segmentation model [Electronic resource] / R. Shougang, et al. – 2020 – Mode of access: [https://www.researchgate.net/publication/349572585\\_Plant\\_diseases\\_and\\_pests\\_detection\\_based\\_on\\_deep\\_learning\\_a\\_review](https://www.researchgate.net/publication/349572585_Plant_diseases_and_pests_detection_based_on_deep_learning_a_review).

33. Ren S. Faster R-CNN: towards real-time object detection with region proposal networks [Electronic resource] / S. Ren, et al. – 2017 – Mode of access: <https://arxiv.org/abs/1506.01497>.

34. Redmon J. You only look once: unified, real-time object detection [Electronic resource] / J. Redmon, et al. – 2015 – Mode of access: <https://arxiv.org/abs/1506.02640>.

35. Fuentes A. A robust deep-learning-based detector for real-time tomato plant diseases and pests detection [Electronic resource] / A. Fuentes, et al. – 2017 – Mode of access: <https://www.mdpi.com/1424-8220/17/9/2022>.

36. Ozguven M. Automatic detection and classification of leaf spot disease in sugar beet using deep learning algorithms [Electronic resource] / M. Ozguven, K. Adem. – 2019 – Mode of access: <https://www.sciencedirect.com/science/article/abs/pii/S0378437119314529>.

37. Zhou G. Rapid detection of rice disease based on FCM-KM and faster R-CNN fusion [Electronic resource] / G. Zhou, et al. – 2019 – Mode of access: <https://doi.org/10.1109/ACCESS.2019.2943454>.

38. Xie X. A deep-learning-based real-time detector for grape leaf diseases using improved convolutional neural networks [Electronic resource] / X. Xie, et al. – 2020 – Mode of access: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC7285655/>.

39. Singh D. Plantdoc: a dataset for visual plant disease detection [Electronic resource] / D. Singh, et al. – 2019 – Mode of access: <https://arxiv.org/abs/1911.10317>.

40. Sun J. Northern maize leaf blight detection under complex field environment based on deep learning [Electronic resource] / J. Sun, et al. – 2020 – Mode of access: <https://doi.org/10.1109/ACCESS.2020.2973658>.

41. Bhatt P. Detection of diseases and pests on images captured in uncontrolled conditions from tea plantations [Electronic resource] / P. Bhatt, S. Sarangi, S. Pappula. – 2019 – Mode of access: <https://doi.org/10.1117/12.2518868>.

42. Zhang B. Crop pest identification based on spatial pyramid pooling and deep convolution neural network [Electronic resource] / B. Zhang, M. Zhang, Y.

Chen. – 2019 – Mode of access: <http://www.tcsae.org/nygcxben/article/abstract/20191925>.

43. Badrinarayanan V. Segnet: a deep convolutional encoder-decoder architecture for image segmentation [Electronic resource] / V. Badrinarayanan, A. Kendall, R. Cipolla. – 2019 – Mode of access: <https://arxiv.org/abs/1505.07293>.

44. Wang Z. Segmentation of corn leaf disease based on fully convolution neural network [Electronic resource] / Z. Wang, S. Zhang. – 2018 – Mode of access: <https://francis-press.com/papers/149>.

45. Wang X. Segmenting crop disease leaf image by modified fully-convolutional networks [Electronic resource] / X. Wang, Z. Wang, S. Zhang. – 2019 – Mode of access: [https://doi.org/10.1007/978-3-030-26763-6\\_62](https://doi.org/10.1007/978-3-030-26763-6_62).

46. Lin K. Deep learning-based segmentation and quantification of cucumber powdery mildew using convolutional neural network [Electronic resource] / K. Lin, et al. – 2019 – Mode of access: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC6413718/>.

47. Kerkech M. Vine disease detection in UAV multi- spectral images using optimized image registration and deep learning segmentation approach [Electronic resource] / M. Kerkech, A. Hafiane, R. Canals. – 2020 – Mode of access: <https://www.sciencedirect.com/science/article/abs/pii/S016816991932558X>.

48. Stewart E. Quantitative phenotyping of northern leaf blight in UAV images using deep learning [Electronic resource] / E. Stewart, et al. – 2019 – Mode of access: <https://www.mdpi.com/2072-4292/11/19/2209>.

49. Wang Q. Identification of tomato disease types and detection of infected areas based on deep convolutional neural networks and object detection techniques [Electronic resource] / Q. Wang, et al. – 2019 – Mode of access: <https://doi.org/10.1155/2019/9142753>.

50. Barbedo J. Factors influencing the use of deep learning for plant disease recognition [Electronic resource] / J. Barbedo – 2018 – Mode of access: <https://www.sciencedirect.com/science/article/abs/pii/S1537511018303027>.

51. Liu J. Early recognition of tomato gray leaf spot disease based on MobileNetv2-YOLOv3 model [Electronic resource] / J. Liu, X. Wang. – 2020 – Mode of access: <https://plantmethods.biomedcentral.com/articles/10.1186/s13007-020-00624-2>.

52. Глибовець М. Системи штучного інтелекту / М. Глибовець, О. Олецкий – К. : Києво-Могилян. акад., 2002. – 78 с.

53. Newell A. Report on a general problem solving program / A. Newell, J. Shaw, H. Simon. – In IFIP congress (Vol. 256), 1959. – 64 с.

54. Minsky M. A framework for representing knowledge / M. Minsky. – The psychology of computer vision, 1975. – 73 с.

55. Petrick, S. Proceedings of the Second Symposium on Symbolic and Algebraic Manipulation / S. Petrick. – 1971 – 23 с.

56. McCulloch W. A logical calculus of the ideas immanent in nervous activity / W. McCulloch, W. Pitts. – Bull Math Biophys, 1943 – 133 с.

57. McClelland J. Explorations in parallel distributed processing / J. McClelland, D. Rumelhart. – Cambridge, Massachusetts: MIT Press, 1986.

58. Rosenblatt F. The Perceptron. A probabilistic model for information storage and organization in the brain / F. Rosenblatt. – Psychol Rev, 1958 – 408 с.

59. Aleksander I. An introduction to neural computing / I. Aleksander, H. Morton. – London: Chapman & Hall, 1990.

60. Hinton G. How neural networks learn from experience [Electronic resource] / G. Hinton – 1992 – Mode of access: [https://www.ahs-informatik.com/app/download/9993218485/How\\_neural\\_networks\\_learn\\_from\\_experienc.pdf](https://www.ahs-informatik.com/app/download/9993218485/How_neural_networks_learn_from_experienc.pdf).

61. NeuralWare. Neural computing / NeuralWare. – Pittsburgh, Pennsylvania: NeuralWare Inc, 1993.
62. CLEMENTINE user manual – Integral Solutions Limited, 1997.
63. Farabet C. Learning Hierarchical Features for Scene Labeling [Electronic resource] / C. Farabet, et al. – 2013 – Mode of access: <http://yann.lecun.com/exdb/publis/pdf/farabet-pami-13.pdf>.
64. Dai J. Convolutional Feature Masking for Joint Object and Stuff Segmentation [Electronic resource] / J. Dai, et al. – 2015 – Mode of access: <https://arxiv.org/abs/1412.1283>.
65. Noh H. Learning Deconvolution Network for Semantic Segmentation [Electronic resource] / H. Noh, et al. – 2015 – Mode of access: <https://arxiv.org/abs/1505.04366>.
66. Badrinarayanan V. SegNet: A Deep Convolutional Encoder-Decoder Architecture for Robust Semantic Pixel-Wise Labelling [Electronic resource] / V. Badrinarayanan, et al. – 2015 – Mode of access: <https://arxiv.org/abs/1505.07293>.
67. Chen L. Semantic Image Segmentation with Deep Convolutional Nets and Fully Connected CRFs [Electronic resource] / L. Chen, et al. – 2015 – Mode of access: <https://arxiv.org/abs/1412.7062>.
68. Russakovsky O. ImageNet Large Scale Visual Recognition Challenge [Electronic resource] / O. Russakovsky, et al. – 2015 – Mode of access: <https://arxiv.org/abs/1409.0575>.
69. Simonyan K. Very Deep Convolutional Networks for Large-Scale Image Recognition [Electronic resource] / K. Simonyan, A. Zisserman. – 2015 – Mode of access: <https://arxiv.org/pdf/1409.1556.pdf>.
70. He K. Identity Mappings in Deep Residual Networks [Electronic resource] / K. He, et al. – 2016 – Mode of access: <https://arxiv.org/abs/1603.05027>.
71. Perkins D. Transfer of Learning / D. Perkins, G. Salomon. – Oxford, England: Pergamon, 1992.

72. Lin Y.-P. Improving EEG-Based Emotion Classification Using Conditional Transfer Learning [Electronic resource] / Y.-P. Lin, et al. – 2017 – Mode of access: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC5486154>.

73. Weiss K. A survey of transfer learning [Electronic resource] / K. Weiss, T. Khoshgoftaar, D. Wang. – 2016 – Mode of access: <https://journalofbigdata.springeropen.com/articles/10.1186/s40537-016-0043-6>.

74. Day O. A survey on heterogeneous transfer learning [Electronic resource] / O. Day, T. Khoshgoftaar – 2017 – Mode of access: <https://journalofbigdata.springeropen.com/articles/10.1186/s40537-017-0089-0>.

75. PlantVillage. Plants Diseases Dataset for machine learning [Electronic resource] / PlantVillage. – 2019 – Mode of access: <https://plantvillage.psu.edu/>.

76. Meta AI. PyTorch: Open Source Machine Learning Framework / Meta AI. – 2016 – Mode of access: <https://pytorch.org/>.

77. Kroll C. Ecosia: Biological Search Engine / C. Kroll – 2009 – Mode of access: <https://www.ecosia.org/>.


78. Ramprasaath R. Grad-CAM: Visual Explanations from Deep Networks via Gradient-based Localization [Electronic resource] / R. Ramprasaath, et al. – 2016 – Mode of access: <https://arxiv.org/abs/1610.02391>.

79. Mingxing T. EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks [Electronic resource] / T. Mingxing, V. Quoc. – 2019 – Mode of access: <https://arxiv.org/abs/1905.11946>.

80. Поляков Д. Як впровадити алгоритми в агросферу: рішення, факапи, перспективи [Електронний ресурс] / Д. Поляков. – 2022 – Режим доступу: <https://dou.ua/forums/topic/38020/>.

**Додаток А**  
**(обов'язковий)**  
**Приклади розширення набору даних: зображення із застосуванням**  
**лінійних перетворень**

Different Types of Augmentations with PyTorch-Based Augmentations




## Додаток Б

### (обов'язковий)

### Приклади розширення набору даних: накладання різних візуальних ефектів

Different Types of Augmentations with Albumentations





**Додаток В**  
**(обов'язковий)**  
**Приклади виконання передбачень сегментаційної мережі для різних**  
**класів в режимі генерації теплової карти**

