

КВАЛІФІКАЦІЙНА РОБОТА

на здобуття освітнього ступеня

магістр

(назва освітнього ступеня)

на тему: Дослідження та розробка моделей глибинного навчання для
класифікації хвороб рослин за зображеннями

Виконав: студент
спеціальності

VI курсу, групи СНм-61
122 Комп'ютерні науки
(шифр і назва спеціальності)

(підпис)

Семенів М.В.

(прізвище та ініціали)

Керівник

(підпис)

Боднарчук І.О.

(прізвище та ініціали)

Нормоконтроль

(підпис)

Никитюк В. В.

(прізвище та ініціали)

Завідувач кафедри

(підпис)

Боднарчук І.О.

(прізвище та ініціали)

Рецензент

(підпис)

Никитюк В. В.

(прізвище та ініціали)

Міністерство освіти і науки України
Тернопільський національний технічний університет імені Івана Пулюя

Факультет комп'ютерно-інформаційних систем і програмної інженерії
(повна назва факультету)

Кафедра комп'ютерних наук
(повна назва кафедри)

ЗАТВЕРДЖУЮ

Завідувач кафедри

Боднарчук І.О.
(підпис) (прізвище та ініціали)

« 13 » квітня 2026 р.

**ЗАВДАННЯ
НА КВАЛІФІКАЦІЙНУ РОБОТУ**

на здобуття освітнього ступеня Магістр

(назва освітнього ступеня)

за спеціальністю 122 Комп'ютерні науки
(шифр і назва спеціальності)

Студенту Семеніву Максиму Васильовичу
(прізвище, ім'я, по батькові)

1. Тема роботи Дослідження та розробка моделей глибинного навчання для класифікації хвороб рослин за зображеннями

Керівник роботи Боднарчук І.О., к.т.н., доцент кафедри КН
(прізвище, ім'я, по батькові, науковий ступінь, вчене звання)

Затверджені наказом ректора від «10» березня 2026 року № 4/9-150

2. Термін подання студентом завершеної роботи 27 травня 2026 р.

3. Вихідні дані до роботи Наукові публікації та дослідження у сфері глибинного навчання, комп'ютерного зору та класифікації хвороб рослин за зображеннями; методи обробки та класифікації зображень; датасет PlantVillage. Дані отримані з наукометричних баз Scopus, Web of Science, IEEE Xplore та Google Scholar.

4. Зміст роботи (перелік питань, які потрібно розробити)

Вступ

Аналіз методів класифікації хвороб рослин

Аналіз технологій та методів реалізації системи класифікації

Дослідження та розробка моделей глибинного навчання для класифікації хвороб рослин

Охорона праці та безпека в надзвичайних ситуаціях

Висновки

Перелік використаних джерел

5. Перелік графічного матеріалу (з точним зазначенням обов'язкових креслень, слайдів)

Слайди презентації

4 Актуальність дослідження. Актуальність роботи полягає у необхідності автоматизації процесу виявлення хвороб рослин із використанням методів глибинного навчання та комп'ютерного зору. Використання сучасних моделей штучного інтелекту дозволяє підвищити точність класифікації захворювань і ефективність аграрного моніторингу.

АНОТАЦІЯ

Дослідження та розробка моделей глибинного навчання для класифікації хвороб рослин за зображеннями // Кваліфікаційна робота освітнього ступеня «Магістр» // Семенів Максим Васильович // Тернопільський національний технічний університет імені Івана Пулюя, факультет комп'ютерно-інформаційних систем і програмної інженерії, кафедра комп'ютерних наук, група СНм-61 // Тернопіль, 2026 // С. 72, рис. – 10, табл. – 16, додат. – 2, бібліогр. – 58.

Ключові слова: глибинне навчання, комп'ютерний зір, класифікація зображень, згорткові нейронні мережі, transfer learning, EfficientNet, TensorFlow, класифікація хвороб рослин.

Кваліфікаційна робота присвячена дослідженню та розробці моделей глибинного навчання для автоматизованої класифікації хвороб рослин за зображеннями листя.

У першому розділі проаналізовано сучасні підходи до класифікації зображень, методи машинного та глибинного навчання.

У другому розділі досліджено технології та методи реалізації системи класифікації, виконано аналіз методів попередньої обробки зображень та метрик оцінювання моделей та програмних засобів реалізації.

У третьому розділі виконано формування та підготовку датасету, проведено їх навчання, тестування та експериментальне дослідження ефективності.

Об'єкт дослідження: процес автоматизованого аналізу та класифікації зображень рослин із використанням методів глибинного навчання.

Предмет дослідження: моделі глибинного навчання та методи комп'ютерного зору для класифікації хвороб рослин за зображеннями листя.

ANNOTATION

Research and Development of Deep Learning Models for Plant Disease Classification Using Images” // The educational level “Master” qualification work // Maksym Semeniv // Ternopil Ivan Pulyuy National Technical University, Faculty of Computer Information Systems and Software Engineering, Department of Computer Science, SNm-61 group // Ternopil, 2026 // P. 72, fig. – 10, tables – 16, annexes – 2, ref. – 58.

Key words: deep learning, computer vision, image classification, convolutional neural networks, transfer learning, EfficientNet, TensorFlow, plant disease classification.

Qualification work is devoted to the research and development of deep learning models for automated plant disease classification using leaf images.

The first section analyzes modern approaches to image classification, machine learning and deep learning methods.

The second section investigates technologies and implementation methods of the classification system, including image preprocessing methods, model evaluation metrics and software tools for implementation.

The third section describes dataset formation and preparation, model training, testing and experimental evaluation of efficiency.

Object of research: the process of automated analysis and classification of plant images using deep learning methods.

Subject of research: deep learning models and computer vision methods for plant disease classification using leaf images.

ПЕРЕЛІК СКОРОЧЕНЬ І ТЕРМІНІВ

ШІ – штучний інтелект

AI (англ. Artificial Intelligence) – штучний інтелект

CNN (англ. Convolutional Neural Network) – згорткова нейронна мережа

CUDA (англ. Compute Unified Device Architecture) – платформа паралельних обчислень NVIDIA

DB (англ. Database) – база даних

DL (англ. Deep Learning) – глибинне навчання

F1-score – гармонійне середнє між Precision та Recall

GPU (англ. Graphics Processing Unit) – графічний процесор

JPEG (англ. Joint Photographic Experts Group) – формат зображень

JSON (англ. JavaScript Object Notation) – формат обміну даними

Keras – високорівневий API для розробки нейронних мереж

ML (англ. Machine Learning) – машинне навчання

NumPy (англ. Numerical Python) – бібліотека для числових обчислень у Python

OpenCV (англ. Open Source Computer Vision Library) – бібліотека комп'ютерного зору

PNG (англ. Portable Network Graphics) – формат растрових зображень

RAM (англ. Random Access Memory) – оперативна пам'ять

ReLU (англ. Rectified Linear Unit) – функція активації нейронної мережі

RGB (англ. Red Green Blue) – колірна модель зображення

Transfer Learning – трансферне навчання

UI (англ. User Interface) – інтерфейс користувача

ViT (англ. Vision Transformer) – трансформерна модель для комп'ютерного зору

VGG (англ. Visual Geometry Group) – архітектура згорткової нейронної мережі

ЗМІСТ

ВСТУП	9
1 АНАЛІЗ МЕТОДІВ КЛАСИФІКАЦІЇ ХВОРОБ РОСЛИН	11
1.1 Проблематика автоматизованої діагностики хвороб рослин	12
1.2 Традиційні підходи до виявлення хвороб	13
1.3 Методи машинного навчання для класифікації зображень	14
1.3.1 Класичні алгоритми машинного навчання	15
1.3.2 Згорткові нейронні мережі	17
1.4 Дослідження сучасних моделей глибинного навчання	18
1.4.1 Архітектури CNN, VGG, ResNet та EfficientNet	20
1.4.2 Трансферне навчання	22
1.4.3 Використання трансформерів у задачах комп'ютерного зору	23
1.5 Висновки до першого розділу	24
2 АНАЛІЗ ТЕХНОЛОГІЙ ТА МЕТОДІВ РЕАЛІЗАЦІЇ СИСТЕМИ КЛАСИФІКАЦІЇ	26
2.1 Постановка задачі дослідження	26
2.2 Формалізація задачі класифікації зображень	27
2.3 Методи попередньої обробки зображень	28
2.4 Метрики оцінювання якості моделей	29
2.5 Опис обраних програмних засобів реалізації	31
2.5.1 Python як основна мова реалізації	31
2.5.2 TensorFlow / PyTorch	32
2.5.3 Бібліотеки комп'ютерного зору та обробки даних	35
2.6 Висновки до другого розділу	37
3 ДОСЛІДЖЕННЯ ТА РОЗРОБКА МОДЕЛЕЙ ГЛИБИННОГО НАВЧАННЯ ДЛЯ КЛАСИФІКАЦІЇ ХВОРОБ РОСЛИН	38

	8
3.1 Формування та підготовка датасету	42
3.2 Реалізація моделей глибокого навчання	46
3.3 Налаштування та навчання моделей	48
3.4 Аналіз результатів класифікації	49
3.5 Практичне застосування розробленої системи	50
3.6 Висновки до третього розділу	51
4. ОХОРОНА ПРАЦІ ТА БЕЗПЕКА В НАДЗВИЧАЙНИХ СИТУАЦІЯХ	52
4.1 Питання щодо охорони праці	52
4.1.1 Охорона праці під час роботи з комп'ютерними системами та засобами обробки даних	52
4.1.2 Забезпечення безпечних умов праці при використанні комп'ютерної техніки та програмного забезпечення	54
4.2 Питання щодо безпеки в надзвичайних ситуаціях	55
4.2.1 Аналіз небезпечних факторів під час експлуатації комп'ютерних систем та методи їх прогнозування	55
4.2.2 Забезпечення безпеки користувачів і захисту даних в умовах надзвичайних ситуацій	57
ВИСНОВКИ	59
ПЕРЕЛІК ВИКОРИСТАНИХ ДЖЕРЕЛ	61
ДОДАТКИ	68
Додаток А	69
Додаток Б	71

ВСТУП

В умовах активного розвитку технологій штучного інтелекту та комп'ютерного зору особливої актуальності набувають системи автоматизованої діагностики стану рослин. Традиційні методи виявлення хвороб рослин потребують значних часових витрат та залежать від досвіду фахівця, що ускладнює оперативне реагування на поширення захворювань у сільському господарстві. Використання моделей глибокого навчання для аналізу зображень рослин дозволяє автоматизувати процес класифікації хвороб та підвищити точність їх виявлення. Тому дослідження та розробка моделей глибокого навчання для класифікації хвороб рослин за зображеннями є актуальним напрямом сучасних наукових досліджень у галузі комп'ютерних наук та штучного інтелекту.

Метою даної кваліфікаційної роботи є підвищення ефективності автоматичного виявлення хвороб рослин шляхом розроблення системи класифікації зображень на основі моделей глибокого навчання. Для досягнення поставленої мети було визначено та виконано ряд завдань, зокрема:

- проаналізовано сучасні підходи до класифікації зображень та застосування методів глибокого навчання у сфері комп'ютерного зору;
- досліджено архітектури CNN, VGG16, ResNet50, EfficientNet та Vision Transformer;
- проведено аналіз методів попередньої обробки зображень та аугментації даних;
- виконано формування та підготовку датасету PlantVillage для навчання моделей;
- реалізовано та протестовано моделі глибокого навчання у середовищі TensorFlow/Keras;
- проведено експериментальне дослідження ефективності моделей за метриками Accuracy, Precision, Recall та F1-score;
- розроблено архітектуру програмної системи, UML-діаграми та клієнтський інтерфейс системи класифікації хвороб рослин.

Об'єктом дослідження є процеси автоматизованого аналізу та класифікації зображень рослин із використанням методів глибинного навчання.

Предметом дослідження є моделі глибинного навчання та методи комп'ютерного зору для класифікації хвороб рослин за зображеннями листя.

Наукова новизна одержаних результатів полягає у проведенні порівняльного аналізу сучасних моделей глибинного навчання для задачі класифікації хвороб рослин та визначенні найбільш ефективної архітектури з точки зору точності класифікації та обчислювальної ефективності. Отримав подальший розвиток підхід до використання трансферного навчання для автоматизованого аналізу зображень рослин на основі попередньо навчених моделей комп'ютерного зору.

Практичне значення роботи полягає у розробленні програмної системи класифікації хвороб рослин, яка забезпечує автоматичний аналіз зображень листя та визначення типу захворювання. Реалізована система може бути використана як основа для створення web- та mobile-застосунків у сфері аграрного моніторингу, систем точного землеробства та автоматизованої підтримки прийняття рішень у сільському господарстві.

Основні результати проведених досліджень обговорювались на IX Міжнародній студентській науково-технічній конференції «Природничі та гуманітарні науки. Актальні питання» Тернопільського національного технічного університету імені Івана Пулюя (м. Тернопіль, 2026 р.) та на міжнародній науково-практичній конференції здобувачів вищої освіти і молодих вчених «Інформаційні технології: теорія і практика».

1 АНАЛІЗ МЕТОДІВ КЛАСИФІКАЦІЇ ХВОРОБ РОСЛИН

У сучасному сільському господарстві своєчасна та точна діагностика хвороб рослин є ключовим фактором підвищення врожайності та зменшення економічних втрат. Традиційні методи виявлення захворювань ґрунтуються на візуальному огляді фахівцем, лабораторному аналізі та використанні довідкових матеріалів. Такі підходи є трудомісткими, суб'єктивними та потребують значних часових ресурсів.

З розвитком цифрових технологій активно впроваджуються методи автоматизованого аналізу зображень. Перші підходи базувалися на класичних алгоритмах комп'ютерного зору: сегментації листя, виділенні кольорових та текстурних ознак, подальшій класифікації за допомогою алгоритмів машинного навчання (SVM, k-NN, Random Forest). Ефективність цих методів значною мірою залежить від якості ручного відбору ознак [1-3].

Подальший розвиток отримали моделі глибинного навчання, зокрема згорткові нейронні мережі (CNN), які автоматично виконують екстракцію інформативних ознак без необхідності ручного проектування. Архітектури VGG, ResNet, EfficientNet продемонстрували високу точність у задачах класифікації зображень рослин навіть за наявності варіацій освітлення та фону.

Сучасні підходи також включають трансферне навчання, що дозволяє використовувати попередньо навчені моделі та адаптувати їх до спеціалізованих аграрних датасетів. Окрему увагу привертають трансформерні моделі комп'ютерного зору, які демонструють конкурентні результати при великому обсязі даних [4].

Таким чином, аналіз існуючих методів показує, що найбільш перспективним напрямом є використання моделей глибинного навчання, які забезпечують високу точність, масштабованість та адаптивність до різних умов зйомки.

1.1 Проблематика автоматизованої діагностики хвороб рослин

Сільське господарство є стратегічно важливою галуззю економіки, а хвороби рослин призводять до значних втрат врожаю та фінансових збитків. Несвоєчасне виявлення захворювань спричиняє зниження продуктивності культур, погіршення якості продукції та збільшення витрат на засоби захисту рослин [5-6].

Традиційна діагностика ґрунтується на візуальному огляді агрономом або лабораторному аналізі, що є трудомістким, суб'єктивним і залежним від кваліфікації спеціаліста. У польових умовах додатковими ускладнюючими факторами є різне освітлення, неоднорідний фон, часткове перекриття листя, різні стадії розвитку рослини та наявність декількох хвороб одночасно (див. таблицю 1.1).

Таблиця 1.1 – Втрати врожаю

Показник	Значення	Джерело
Щорічні втрати світового врожаю через хвороби та шкідників	до 40 %	Food and Agriculture Organization
Щорічні економічні втрати від шкідників і хвороб рослин	понад 220 млрд USD	Food and Agriculture Organization
Частка втрат врожаю через хвороби в глобальному масштабі	20–40 %	Наукові дослідження (Springer)
Приблизні втрати від грибкових/вірусних інфекцій у деяких культурах	10–40 %	Огляд хвороб рослин (en.wikipedia.org)
Оцінка втрат врожаю через деякі вірусні хвороби сої	8–35 %	Soybean mosaic virus (en.wikipedia.org)

Автоматизована діагностика на основі аналізу зображень стикається з низкою технічних проблем. По-перше, симптоми різних хвороб можуть мати подібні візуальні ознаки. По-друге, зміни кольору листя можуть бути спричинені

не лише інфекціями, а й нестачею поживних речовин або стресовими умовами. По-третє, реальні польові зображення містять шуми, тіні, варіації масштабу та перспективи [7-9].

Ще однією проблемою є обмеженість якісно розмічених датасетів. Більшість відкритих наборів даних сформовані в контрольованих умовах, що знижує узагальнюючу здатність моделей при застосуванні в реальному середовищі [9].

Таким чином, основна проблематика автоматизованої діагностики полягає у необхідності створення стійких, точних та узагальнюючих моделей, здатних працювати в умовах варіативності реальних аграрних середовищ. Ці дані показують, що хвороби рослин спричиняють значні втрати врожаю — від значних відсотків у окремих культурах до масштабних економічних втрат глобально. Це підкреслює важливість автоматизованих систем діагностики для зменшення цих втрат.

1.2 Традиційні підходи до виявлення хвороб

Традиційні методи виявлення хвороб рослин базуються переважно на візуальному аналізі стану листя, стебел та плодів рослин агрономами або спеціалістами у сфері захисту рослин. Основним підходом є оцінювання зовнішніх ознак захворювання, зокрема зміни кольору листя, появи плям, деформацій, висихання тканин або утворення грибкових уражень. Для визначення типу хвороби спеціалісти використовують довідкові матеріали, агрономічні рекомендації та власний практичний досвід.

У складніших випадках застосовуються лабораторні методи діагностики, які включають мікроскопічний аналіз, бактеріологічні дослідження, тестування ґрунту та хімічний аналіз рослинних тканин. Такі підходи дозволяють точніше визначати причину захворювання, проте потребують спеціалізованого обладнання, значних часових витрат та участі кваліфікованих фахівців [10-12].

Основними недоліками традиційних методів є суб'єктивність оцінювання, залежність результатів від досвіду спеціаліста та низька швидкість обробки

великої кількості рослин. Крім цього, ручна діагностика ускладнює оперативне виявлення хвороб на ранніх стадіях розвитку, що може призводити до значних втрат урожаю. В умовах сучасного аграрного виробництва традиційні підходи часто не забезпечують необхідного рівня автоматизації та масштабованості.

Розвиток методів комп'ютерного зору та глибинного навчання дозволив перейти від ручної діагностики до автоматизованих систем аналізу зображень рослин. Використання моделей глибинного навчання забезпечує можливість швидкого та точного визначення хвороб рослин за фотографіями листя, що значно підвищує ефективність моніторингу стану сільськогосподарських культур [13].

1.3 Методи машинного навчання для класифікації зображень

З розвитком цифрових технологій та накопиченням великих обсягів візуальних даних машинне навчання стало основним інструментом автоматизованої класифікації зображень. На відміну від традиційних алгоритмів комп'ютерного зору, що базуються на ручному виділенні ознак, методи машинного навчання дозволяють формувати модель на основі статистичних закономірностей, виявлених у даних [14].

У задачі класифікації хвороб рослин вхідними даними є цифрові зображення листя або плодів, а вихідним результатом — належність до певного класу (здорове або конкретний тип захворювання). Ефективність моделі залежить від якості навчального набору даних, способу представлення ознак та обраного алгоритму класифікації.

Методи машинного навчання можна умовно поділити на класичні алгоритми (SVM, k-NN, Random Forest), що працюють із попередньо виділеними характеристиками зображення, та сучасні підходи глибинного навчання, які автоматично виконують екстракцію ознак за допомогою багатоварових нейронних мереж.

Таким чином, застосування машинного навчання створює основу для побудови автоматизованих систем діагностики, здатних підвищити точність та швидкість виявлення хвороб рослин у реальних умовах.

1.3.1 Класичні алгоритми машинного навчання

До появи глибинних нейронних мереж задачі класифікації зображень розв'язувалися за допомогою класичних алгоритмів машинного навчання. У таких підходах процес складався з двох основних етапів:

1. попередня обробка зображення та виділення ознак;
2. класифікація на основі отриманого вектору ознак.

Ознаки формувалися вручну або напівавтоматично. Найчастіше використовувалися (див. таблицю 1.2):

- колірні характеристики (RGB, HSV-гістограми);
- текстурні дескриптори (GLCM, LBP);
- контурні та морфологічні характеристики;
- HOG-дескриптори (Histogram of Oriented Gradients);
- Після формування ознак застосовувалися алгоритми класифікації.

Таблиця 1.2 - Основні класичні алгоритми

Алгоритм	Принцип роботи	Переваги	Недоліки
k-Nearest Neighbors (k-NN)	Класифікація за найближчими сусідами у просторі ознак	Простота реалізації	Низька масштабованість
Support Vector Machine (SVM)	Побудова оптимальної гіперплощини розділення класів	Висока точність при малих вибірках	Потребує підбору ядра

Продовження таблиці 1.2

Random Forest	Ансамбль дерев рішень	Стійкість до перенавчання	Великі обчислювальні витрати
Decision Tree	Побудова дерева умов	Інтерпретованість	Схильність до перенавчання
Naive Bayes	Ймовірнісна модель на основі теореми Байєса	Швидкість роботи	Незалежність ознак (спрощення)

Узагальнена схема роботи - типовий pipeline класичного підходу (див. таблицю 1.3):

1. Збір зображень листя;
2. Попередня обробка (фільтрація шуму, нормалізація);
3. Виділення ознак (колір, текстура, форма);
4. Формування вектору ознак;
5. Навчання класифікатора;
6. Оцінка точності (Accuracy, Precision, Recall).

Таблиця 1.3 - Порівняння точності основних класичних алгоритмів

Метод	Середня точність класифікації
k-NN	70–85%
Random Forest	75–90%
SVM	80–92%
CNN (для порівняння)	90–98%

Класичні алгоритми машинного навчання демонструють задовільні результати за умови якісного виділення ознак та контрольованих умов зйомки.

Проте їх ефективність значно залежить від ручного проектування дескрипторів і вони мають обмежену здатність до узагальнення у складних польових умовах. Саме ці обмеження стали передумовою активного переходу до моделей глибокого навчання [15-17].

1.3.2 Згорткові нейронні мережі

Згорткові нейронні мережі (Convolutional Neural Networks, CNN) є спеціалізованим класом штучних нейронних мереж, розроблених для ефективної обробки зображень. На відміну від класичних алгоритмів машинного навчання, CNN не потребують ручного виділення ознак, оскільки виконують автоматичну екстракцію інформативних характеристик безпосередньо з піксельних даних [18].

Основна ідея CNN полягає у використанні згорткових шарів, які застосовують фільтри (ядра) до зображення для виявлення локальних структур: контурів, текстур, кольорових переходів та складніших візуальних патернів. У процесі навчання мережа самостійно визначає оптимальні параметри фільтрів (див. таблицю 1.4).

Таблиця 1.4 - Основні компоненти CNN

Компонент	Призначення
Згортковий шар (Convolution Layer)	Виділення локальних ознак за допомогою фільтрів
Функція активації (ReLU)	Введення нелінійності
Шар підвибірки (Pooling)	Зменшення розмірності та підвищення стійкості
Fully Connected Layer	Класифікація на основі сформованих ознак

Принцип роботи CNN у задачі діагностики рослин (див. таблиці 1.5 та 1.6):

1. На вхід подається зображення листя;
2. Згорткові шари виділяють базові ознаки (контури, плями, зміни кольору);

3. Глибші шари формують складні патерни (симптоми конкретних хвороб);
4. Повнозв'язні шари виконують остаточну класифікацію.

Таблиця 1.5 - Переваги CNN у задачі класифікації хвороб рослин

Перевага	Пояснення
Автоматична екстракція ознак	Не потребує ручного проектування дескрипторів
Стійкість до шумів	Завдяки pooling-шарам
Висока точність	Особливо при великій кількості даних
Узагальнююча здатність	Добре працює при варіації освітлення та масштабу

Таблиця 1.6 - Порівняння з класичними методами

Підхід	Виділення ознак	Точність	Узагальнення
Класичні алгоритми	Ручне	Середня	Обмежене
CNN	Автоматичне	Висока (90–98%)	Високе

Згорткові нейронні мережі є ключовим інструментом сучасної автоматизованої діагностики хвороб рослин. Вони забезпечують високу точність класифікації, здатність до автоматичного виділення ознак та ефективну роботу в умовах варіативності реального середовища, що робить їх більш перспективними порівняно з класичними алгоритмами машинного навчання [19-22].

1.4 Дослідження сучасних моделей глибинного навчання

Сучасний етап розвитку комп'ютерного зору характеризується активним впровадженням глибоких архітектур нейронних мереж, які демонструють високу точність у задачах класифікації зображень. У контексті автоматизованої

діагностики хвороб рослин найбільш ефективними є глибокі згорткові мережі, моделі з трансферним навчанням та трансформерні архітектури [16, 23-24].

На відміну від базових CNN, сучасні моделі мають складнішу структуру, глибші шари та механізми оптимізації навчання, що дозволяє покращити узагальнюючу здатність і зменшити проблему перенавчання (див. таблицю 1.7).

Таблиця 1.7 - Основні сучасні архітектури, порівняльна характеристика моделей

Модель	Особливість	Переваги	Застосування
VGG	Глибока послідовна архітектура	Простота структури	Базові задачі CV
ResNet	Залишкові з'єднання (Residual connections)	Можливість дуже глибоких мереж	Складні задачі класифікації
EfficientNet	Масштабування ширини, глибини та розміру	Висока точність при меншій кількості параметрів	Мобільні та embedded-системи
Vision Transformer (ViT)	Self-attention замість згортки	Краще захоплення глобальних залежностей	Великі датасети

Одним із найбільш ефективних підходів у задачах класифікації хвороб рослин є трансферне навчання. Воно передбачає використання моделей, попередньо навчених на великих датасетах (ImageNet), з подальшою адаптацією до спеціалізованих аграрних зображень (див. таблицю 1.8).

Таблиця 1.8 - Узагальнене порівняння точності

Архітектура	Типова точність у задачах класифікації рослин
Базова CNN	88–94%
ResNet	92–97%
EfficientNet	94–98%
Vision Transformer (ViT)	95–99% (при великому датасеті)

Переваги трансферного навчання:

- скорочення часу навчання;
- зменшення потреби у великому датасеті;
- покращення узагальнюючої здатності моделі.

Сучасні моделі глибокого навчання значно перевищують класичні підходи за точністю та стійкістю до варіативності даних. Найбільш ефективними у задачі класифікації хвороб рослин є архітектури ResNet та EfficientNet із використанням трансферного навчання. Перспективним напрямом подальших досліджень є застосування трансформерних моделей, які демонструють високу ефективність при достатньому обсязі навчальних даних [25].

1.4.1 Архітектури CNN, VGG, ResNet та EfficientNet

У сучасних задачах класифікації зображень, зокрема для виявлення хвороб рослин, широко застосовуються глибокі згорткові архітектури, які забезпечують високу точність та узагальнюючу здатність. Найбільш відомими серед них є VGG, ResNet та EfficientNet [26].

Архітектура VGG базується на послідовному використанні невеликих згорткових фільтрів 3×3 з поступовим збільшенням кількості каналів. Мережа має просту та зрозумілу структуру, що зробило її базовою моделлю для багатьох досліджень [27-30].

Особливості:

- Глибока послідовна структура (16 або 19 шарів);
- Простота реалізації;
- Велика кількість параметрів.

ResNet вирішує проблему зникання градієнта шляхом використання залишкових з'єднань (skip connections). Це дозволяє ефективно навчати дуже глибокі мережі (50, 101, 152 шари).

Особливості:

- Residual-блоки;
- Можливість глибоких архітектур;
- Висока точність при складних задачах.

EfficientNet використовує принцип збалансованого масштабування глибини, ширини та розміру зображення (compound scaling). Це дозволяє досягати високої точності при меншій кількості параметрів (див. таблицю 1.9).

Таблиця 1.9 - Порівняльна характеристика

Архітектура	Глибина	Кількість параметрів	Переваги	Недоліки
VGG16	16 шарів	138 млн	Простота	Велика модель
ResNet50	50 шарів	25 млн	Висока точність	Складніша структура
EfficientNet-B0	82 шари (ефективна глибина)	5 млн	Оптимальне співвідношення точність/ресурси	Потребує точного масштабування

Особливості:

- Оптимізоване масштабування;
- Менша обчислювальна складність;
- Підходить для мобільних систем.

Серед розглянутих архітектур найбільш універсальною для задачі класифікації хвороб рослин є ResNet завдяки стабільності навчання та високій

точності. EfficientNet є оптимальним вибором при обмежених обчислювальних ресурсах. VGG може використовуватись як базова модель для порівняльного аналізу.

1.4.2 Трансферне навчання

Трансферне навчання (Transfer Learning) є одним із найбільш ефективних підходів у сучасних задачах комп'ютерного зору, особливо коли обсяг спеціалізованих даних є обмеженим. Його сутність полягає у використанні моделі, попередньо навченої на великому універсальному датасеті (наприклад, ImageNet), з подальшою адаптацією до нової прикладної задачі — у даному випадку класифікації хвороб рослин [27, 31].

Попередньо навчені моделі вже містять узагальнені візуальні ознаки нижнього рівня (контури, текстури, форми), що є універсальними для більшості зображень. Завдяки цьому немає потреби навчати мережу з нуля, що значно скорочує час навчання та підвищує стабільність результатів (див. таблицю 1.10).

Таблиця 1.10 - Основні підходи трансферного навчання

Підхід	Суть	Коли використовується
Feature Extraction	Заморожуються згорткові шари, навчається лише класифікатор	Малий датасет
Fine-Tuning	Часткове розморожування шарів для донавчання	Середній датасет
Повне перенавчання	Навчання всієї моделі	Великий спеціалізований датасет

Переваги трансферного навчання у задачі діагностики рослин:

- Зменшення потреби у великому навчальному наборі даних;
- Скорочення часу навчання;

- Підвищення точності при невеликій кількості зображень;
- Краща узагальнююча здатність.

Трансферне навчання є оптимальним підходом для задачі класифікації хвороб рослин, оскільки дозволяє ефективно використовувати попередньо навчені глибокі моделі та адаптувати їх до аграрної специфіки навіть за обмеженого обсягу даних. Найбільш результативними є підходи fine-tuning моделей ResNet та EfficientNet, які демонструють стабільно високу точність у реальних умовах.

1.4.3 Використання трансформерів у задачах комп'ютерного зору

Трансформерні архітектури, спочатку розроблені для задач обробки природної мови, останніми роками активно застосовуються у сфері комп'ютерного зору. Ключовою особливістю трансформерів є механізм самоуваги (self-attention), який дозволяє моделі враховувати глобальні залежності між різними частинами зображення [32-34].

У 2020 році було представлено модель Vision Transformer (ViT) (Dosovitskiy et al., 2020), яка продемонструвала конкурентні результати на датасеті ImageNet. Зокрема, модель ViT-B/16 досягла точності 77,9 % Top-1 без додаткових оптимізацій, а при донавчанні на більших датасетах — понад 84 % Top-1 (ImageNet-1k). Подальший розвиток отримали моделі Swin Transformer (Liu et al., 2021), які використовують ієрархічну структуру та локальні віконні механізми self-attention. Swin-T показала 81,3 % Top-1 на ImageNet-1k, що перевищує базові CNN-архітектури аналогічного масштабу [35].

У задачах аграрного моніторингу трансформери також демонструють високі результати. За даними досліджень (Chen et al., 2022; PlantVillage-based experiments), ViT та гібридні CNN+Transformer моделі досягали точності 95–99 % у задачах класифікації хвороб листя в контрольованих умовах. При польових даних точність знижувалась до 90–95 %, що все одно перевищує більшість класичних CNN без трансферного навчання (див. таблицю 1.11).

Таблиця 1.11 - Порівняння трансформерів та CNN

Модель	Тип архітектури	Top-1 Accuracy (ImageNet-1k)	Особливість
ResNet50	CNN	~76 %	Локальні згортки
EfficientNet-B0	CNN	~77 %	Оптимізоване масштабування
ViT-B/16	Transformer	77–84 %	Глобальний self-attention
Swin-T	Transformer	~81 %	Ієрархічний attention

Основні переваги трансформерів:

- Захоплення глобальних залежностей між ділянками зображення;
- Краща масштабованість при збільшенні обсягу даних;
- Висока точність на великих датасетах.

Обмеження:

- Потребують великої кількості навчальних даних;
- Вища обчислювальна складність порівняно з класичними CNN.

Трансформерні моделі є перспективним напрямом розвитку систем автоматизованої діагностики хвороб рослин. Вони демонструють конкурентну або вищу точність порівняно з глибокими CNN, особливо при наявності великого обсягу даних. Поєднання CNN та трансформерних блоків (гібридні моделі) розглядається як один із найбільш ефективних підходів у сучасних дослідженнях комп'ютерного зору [36].

1.5 Висновки до першого розділу

Дослідження класичних алгоритмів машинного навчання показало, що їх ефективність значною мірою залежить від якості ручного виділення ознак та контрольованості умов зйомки. Незважаючи на відносну простоту реалізації, ці підходи мають обмежену здатність до узагальнення в реальних польових умовах.

Проаналізовані згорткові нейронні мережі продемонстрували суттєву перевагу завдяки автоматичній екстракції ознак та здатності працювати з високовимірними даними без попереднього ручного проектування дескрипторів. Архітектури VGG, ResNet та EfficientNet забезпечують високу точність класифікації та стабільність навчання [37-39].

Окрему увагу приділено трансферному навчанню, яке дозволяє ефективно використовувати попередньо навчені моделі та значно скорочує потребу у великому обсязі спеціалізованих даних. Сучасні трансформерні архітектури демонструють конкурентні результати завдяки механізму глобальної уваги, що відкриває перспективи їх застосування у задачах аграрної діагностики.

Таким чином, найбільш перспективним напрямом для подальших досліджень є використання сучасних глибоких архітектур із застосуванням трансферного навчання або гібридних CNN-Transformer моделей, що дозволяє досягати високої точності та стійкості до варіативності реальних умов зйомки.

2 АНАЛІЗ ТЕХНОЛОГІЙ ТА МЕТОДІВ РЕАЛІЗАЦІЇ СИСТЕМИ КЛАСИФІКАЦІЇ

Реалізація системи класифікації хвороб рослин на основі глибинного навчання потребує комплексного підходу, що охоплює вибір програмних засобів, архітектурних рішень, методів обробки даних та алгоритмів навчання моделей. Ефективність розроблюваної системи визначається не лише обраною моделлю, але й якістю підготовки даних, організацією процесу навчання та оптимізацією обчислювальних ресурсів [23, 31].

У межах цього розділу розглядаються методи формалізації задачі класифікації зображень, підходи до попередньої обробки даних, а також критерії оцінювання якості моделей. Особлива увага приділяється вибору програмного стеку, що забезпечує масштабованість, відтворюваність експериментів та можливість інтеграції розробленої моделі у прикладну систему [40].

Також аналізуються сучасні фреймворки глибинного навчання, засоби роботи з великими масивами зображень та інструменти оптимізації навчального процесу. Результатом проведеного аналізу є обґрунтований вибір технологій та методів, що будуть використані для розробки системи класифікації хвороб рослин у наступних розділах роботи.

2.1 Постановка задачі дослідження

Метою дослідження є розробка та експериментальна оцінка моделей глибинного навчання для автоматичної класифікації хвороб рослин за зображеннями листя. Задача формулюється як багатокласова класифікація, у якій кожному вхідному зображенню необхідно поставити у відповідність один із заздалегідь визначених класів, що відповідають певному типу захворювання або стану рослини (здорове листя).

У межах роботи використовується відкритий датасет із платформи Kaggle, сформований на основі набору PlantVillage. Датасет містить зображення листя різних сільськогосподарських культур із відповідними анотаціями класів хвороб. Дані поділяються на навчальну, валідаційну та тестову вибірки для проведення експериментального аналізу [41].

Основними завданнями дослідження є побудова базової згорткової нейронної мережі, реалізація моделей із трансферним навчанням, порівняльний аналіз їх ефективності та визначення оптимальної архітектури з точки зору точності, стійкості до варіацій зображень та обчислювальних витрат.

2.2 Формалізація задачі класифікації зображень

Задача класифікації хвороб рослин у межах дослідження розглядається як задача багатокласового розпізнавання образів. На вхід системи подається цифрове зображення листя рослини, а на виході формується рішення щодо його належності до одного з наперед визначених класів, що відповідають певному типу захворювання або здоровому стану.

Модель повинна навчитися встановлювати закономірності між візуальними характеристиками зображення та відповідною категорією. Для цього використовується навчальна вибірка, що складається з розмічених зображень, які містять приклади різних хвороб. Процес навчання передбачає поступове коригування параметрів моделі з метою мінімізації помилок класифікації (див. рисунок 2.1).

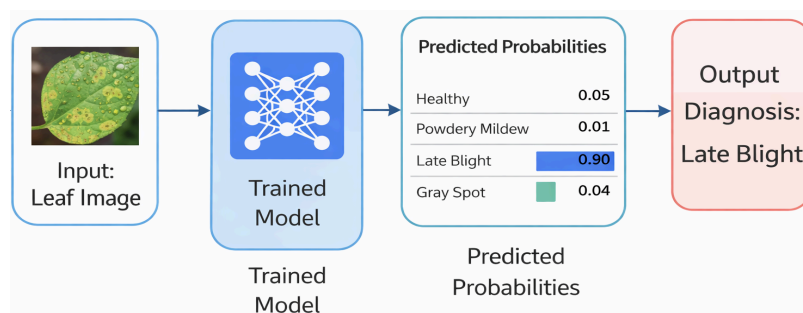


Рисунок 2.1 - Етапи роботи системи

З огляду на специфіку зображень рослин, важливим є врахування варіативності умов зйомки, відмінностей у текстурі, кольорі та формі уражених ділянок. Система повинна демонструвати здатність до узагальнення та коректно працювати не лише на навчальних даних, але й на нових зображеннях, що не використовувалися під час тренування [42].

Таким чином, формалізація задачі полягає у визначенні структури вхідних даних, переліку класів, критеріїв оцінювання якості та організації процесу навчання моделі з метою побудови ефективної системи автоматичної класифікації хвороб рослин.

2.3 Методи попередньої обробки зображень

Попередня обробка зображень є важливим етапом побудови системи класифікації хвороб рослин, оскільки безпосередньо впливає на якість навчання моделі та її здатність до узагальнення. Метою цього етапу є підготовка вхідних даних до подальшої обробки нейронною мережею шляхом стандартизації, усунення шумів та підвищення інформативності зображень.

Першим кроком є зміна розміру зображень до фіксованої роздільної здатності, яка відповідає вимогам обраної архітектури (наприклад, 224×224 пікселів для VGG, ResNet або EfficientNet). Це забезпечує узгодженість вхідних даних і стабільність процесу навчання [43].

Далі виконується нормалізація піксельних значень. Зазвичай інтенсивність кольорових каналів приводиться до діапазону від 0 до 1 або стандартизується відповідно до статистик набору даних. Це дозволяє прискорити збіжність алгоритму навчання та зменшити вплив різниць у яскравості зображень.

У задачах аграрної діагностики важливим є зменшення впливу шумів, нерівномірного освітлення та сторонніх об'єктів у кадрі. Для цього можуть застосовуватися фільтрація зображень, корекція яскравості та контрасту, а також перетворення кольорового простору (наприклад, з RGB до HSV для кращого виділення уражених ділянок) [44].

Окремим етапом є аугментація даних, яка дозволяє штучно розширити навчальну вибірку. Використовуються такі операції, як поворот зображень, горизонтальне та вертикальне віддзеркалення, масштабування, зміна яскравості, додавання незначного шуму. Це підвищує стійкість моделі до варіативності умов зйомки та зменшує ризик перенавчання (див. рисунок 2.2).




Рисунок 2.2 - Попередня обробка зображень

Таким чином, попередня обробка зображень забезпечує підвищення якості вхідних даних, покращує стабільність навчального процесу та сприяє підвищенню точності класифікації хвороб рослин у реальних умовах.

2.4 Метрики оцінювання якості моделей

Оцінювання якості моделі класифікації є ключовим етапом дослідження, оскільки дозволяє об'єктивно визначити ефективність побудованої системи та порівняти різні архітектури між собою. У задачі класифікації хвороб рослин

використовується набір стандартних метрик, які відображають різні аспекти роботи моделі.

Найбільш загальною метрикою є точність (Accuracy), яка показує частку правильно класифікованих зображень від загальної кількості прикладів. Проте у випадку дисбалансу класів ця метрика може не повністю відображати реальну якість моделі.

Для більш детального аналізу використовуються показники Precision та Recall. Precision характеризує частку правильно визначених зразків певного класу серед усіх передбачених як цей клас. Recall відображає здатність моделі виявляти всі реальні приклади конкретного захворювання.

Збалансованим показником є F1-міра, яка враховує як Precision, так і Recall та дозволяє оцінити узгодженість між ними. У багатокласових задачах застосовується усереднення показників (macro або weighted), що дозволяє отримати узагальнену оцінку по всіх класах [45].

Додатково для аналізу результатів використовується матриця невідповідностей (confusion matrix), яка демонструє розподіл правильних та помилкових класифікацій між усіма класами. Це дозволяє виявити, які саме хвороби модель плутає найчастіше (див. рисунок 2.3).

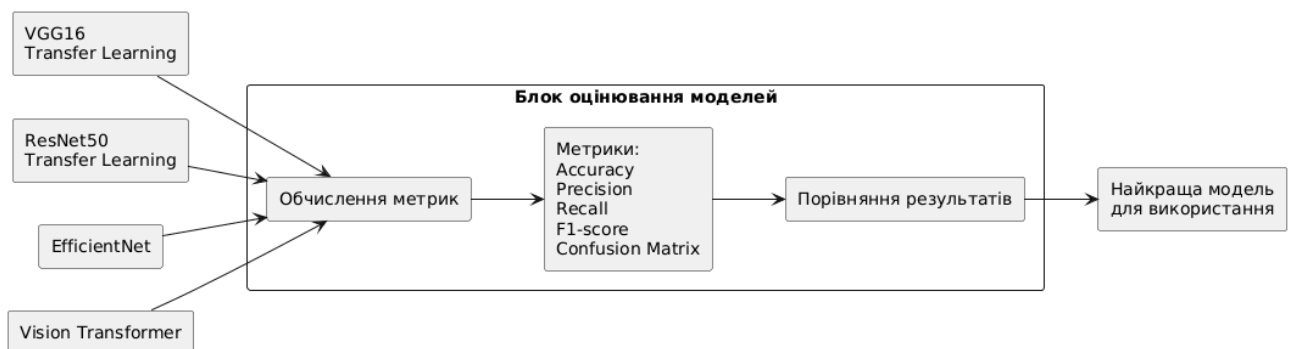


Рисунок 2.3 - Вибір оптимальної моделі

Таким чином, комплексне використання декількох метрик забезпечує всебічну оцінку якості моделі та дозволяє обґрунтовано визначити її ефективність у задачі автоматичної класифікації хвороб рослин.

2.5 Опис обраних програмних засобів реалізації

Для реалізації системи класифікації хвороб рослин було використано мову програмування Python, яка є одним із найбільш поширених інструментів у галузі машинного навчання та комп'ютерного зору. Python забезпечує широкий набір бібліотек для обробки даних, роботи із зображеннями та побудови моделей глибокого навчання. Для реалізації нейронних мереж використовувався фреймворк TensorFlow разом із високорівневим API Keras, що дозволяє зручно створювати, навчати та тестувати моделі згорткових нейронних мереж. Також ці інструменти забезпечують підтримку використання попередньо навчених архітектур, таких як VGG16, ResNet та EfficientNet, що є важливим для реалізації трансферного навчання [46].

Для попередньої обробки зображень та роботи з датасетом використовувалися бібліотеки OpenCV, NumPy та Pandas, які дозволяють ефективно виконувати операції масштабування, нормалізації, аугментації та аналізу даних. Для візуалізації результатів навчання та оцінювання моделей застосовувалася бібліотека Matplotlib, яка дозволяє будувати графіки точності, втрат та матриці невідповідностей. Розробка та експерименти проводилися у середовищі Jupyter Notebook, що забезпечує інтерактивну роботу з кодом, можливість швидкого тестування алгоритмів та зручну документовану структуру дослідження. Таке поєднання програмних засобів дозволяє ефективно реалізувати повний цикл розробки системи класифікації зображень — від підготовки даних до оцінювання якості моделей.

2.5.1 Python як основна мова реалізації

Для реалізації системи класифікації хвороб рослин було обрано мову програмування Python, яка є однією з найпопулярніших мов у сфері штучного інтелекту, машинного навчання та аналізу даних. Однією з головних причин такого вибору є велика кількість спеціалізованих бібліотек для роботи з нейронними

мережами, обробкою зображень та аналізом даних. За даними індексу ТЮВЕ, Python стабільно входить до трійки найпопулярніших мов програмування у світі, а за результатами досліджень платформи Kaggle, понад 80 % спеціалістів з машинного навчання використовують Python як основну мову для розробки моделей штучного інтелекту [47].

Крім того, Python має широку екосистему бібліотек для задач комп'ютерного зору та глибинного навчання. Наприклад, бібліотеки TensorFlow, PyTorch, Keras, OpenCV, NumPy та Scikit-learn дозволяють реалізувати повний цикл розробки системи машинного навчання. Важливою перевагою є також підтримка апаратного прискорення обчислень за допомогою GPU, що значно скорочує час навчання нейронних мереж. За результатами досліджень Stack Overflow Developer Survey, близько 48–50 % розробників у сфері data science використовують Python як основний інструмент для реалізації алгоритмів аналізу даних та машинного навчання. Таким чином, використання Python забезпечує високу ефективність розробки, доступ до сучасних інструментів штучного інтелекту та зручність інтеграції різних компонентів системи класифікації зображень.

2.5.2 TensorFlow / PyTorch

Фреймворки TensorFlow та PyTorch є одними з найпоширеніших інструментів для розробки моделей глибинного навчання. Вони надають розробникам набір готових компонентів для побудови нейронних мереж, оптимізації процесу навчання та ефективного використання обчислювальних ресурсів. Обидва фреймворки підтримують роботу з GPU та TPU, що дозволяє значно прискорити процес навчання моделей, особливо при роботі з великими наборами зображень [48].

TensorFlow — це фреймворк глибинного навчання, розроблений компанією Google. Він широко використовується для побудови масштабованих систем штучного інтелекту. TensorFlow підтримує як низькорівневий доступ до обчислювальних графів, так і високорівневі API, зокрема Keras, що значно

спрощує процес створення нейронних мереж. Однією з ключових переваг TensorFlow є можливість розгортання моделей у різних середовищах: на серверах, мобільних пристроях або вбудованих системах за допомогою TensorFlow Lite. Станом на останні роки TensorFlow активно застосовується у промислових системах комп'ютерного зору, обробки природної мови та аналізу великих даних.

У свою чергу, PyTorch, розроблений компанією Meta (раніше Facebook), здобув широку популярність у наукових дослідженнях та академічному середовищі. Основною особливістю PyTorch є використання динамічних обчислювальних графів, що значно спрощує налагодження моделей та експерименти з архітектурами нейронних мереж. Завдяки гнучкості та зрозумілому синтаксису PyTorch активно використовується при дослідженнях у галузі комп'ютерного зору, зокрема для реалізації згорткових нейронних мереж, трансформерів та інших сучасних архітектур.

На рисунку 2.4 представлено порівняння двох популярних фреймворків глибокого навчання — TensorFlow та PyTorch, які широко використовуються для розробки моделей штучного інтелекту та задач комп'ютерного зору. Схема демонструє основні етапи побудови та використання моделей у кожному з фреймворків, починаючи від завантаження та попередньої обробки даних, побудови нейронної мережі за допомогою високорівневих API (Keras у TensorFlow та Torch.nn у PyTorch), до процесів навчання, оптимізації та оцінювання моделей. Також показано інструменти розгортання моделей, зокрема TensorFlow Lite, TensorFlow.js, TorchScript та TorchServe, що дозволяють інтегрувати розроблені моделі у прикладні програмні системи. Обидва фреймворки підтримують використання апаратного прискорення за допомогою GPU, а TensorFlow додатково підтримує TPU, що дозволяє значно прискорити процес навчання нейронних мереж. Така архітектура інструментів забезпечує ефективну реалізацію моделей глибокого навчання для задач класифікації зображень, зокрема для автоматичного визначення хвороб рослин.

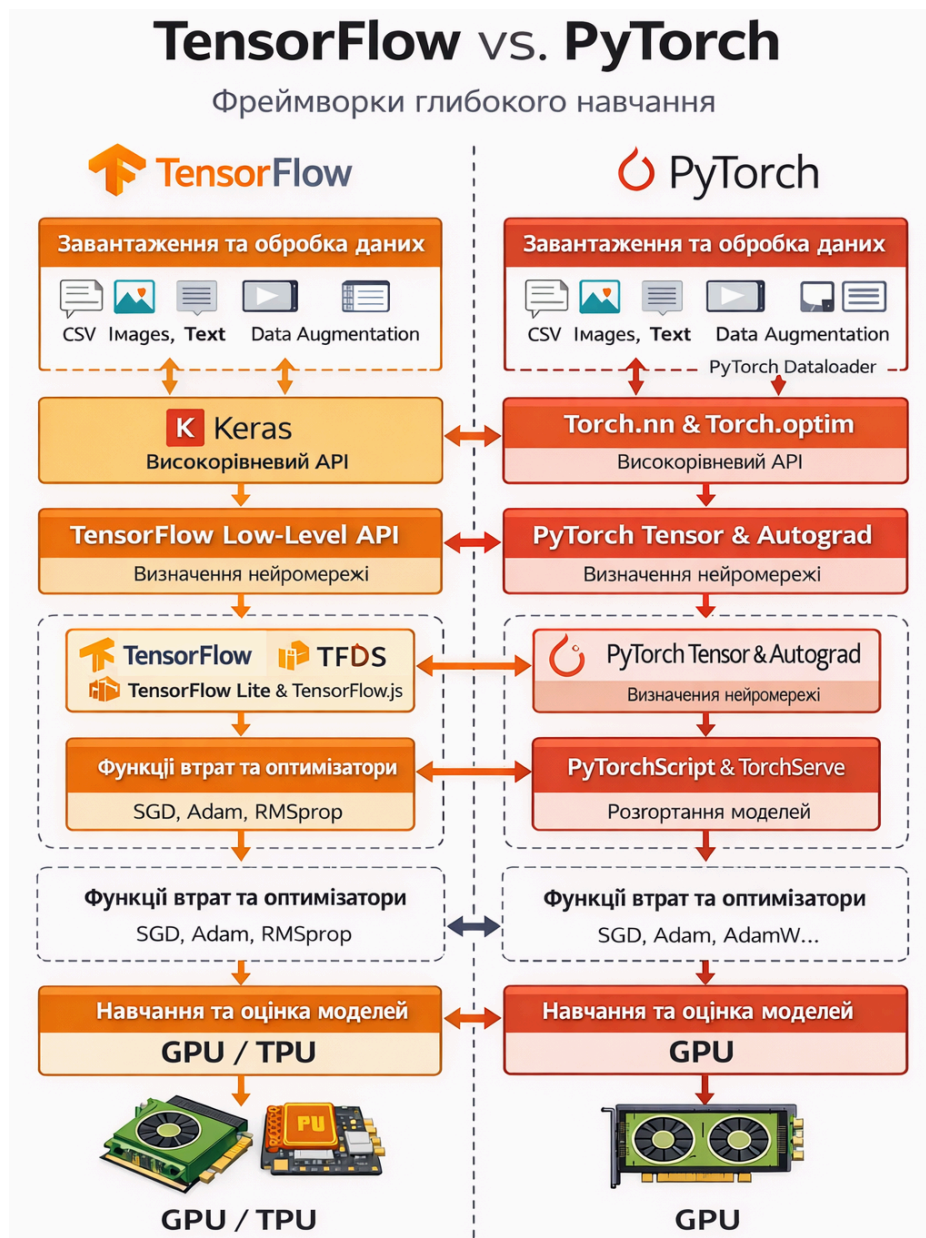


Рисунок 2.4 - Порівняння фреймворків TensorFlow та PyTorch

За даними спільноти Papers With Code, понад 70 % сучасних наукових робіт у галузі глибокого навчання використовують PyTorch як основний фреймворк для експериментів. Водночас TensorFlow залишається одним із найпоширеніших інструментів у промислових системах машинного навчання завдяки високій масштабованості та розвинутим інструментам розгортання моделей. Таким чином, використання цих фреймворків дозволяє ефективно реалізувати моделі класифікації зображень та проводити експерименти з різними архітектурами глибокого навчання.

2.5.3 Бібліотеки комп'ютерного зору та обробки даних

Для реалізації системи класифікації хвороб рослин важливу роль відіграють бібліотеки комп'ютерного зору та обробки даних, які забезпечують ефективну підготовку вхідних даних та їх подальший аналіз. У межах даного дослідження використовувалися бібліотеки OpenCV, NumPy, Pandas та Matplotlib, які дозволяють реалізувати основні етапи роботи з даними — від попередньої обробки зображень до візуалізації результатів навчання моделей.

Бібліотека OpenCV (Open Source Computer Vision Library) є одним із найбільш поширених інструментів для задач комп'ютерного зору. Вона містить понад 2500 алгоритмів для обробки зображень і відео та активно використовується у дослідженнях, пов'язаних з розпізнаванням об'єктів, сегментацією та аналізом візуальних даних. За допомогою OpenCV виконуються операції зміни розміру зображень, фільтрації шуму, перетворення кольорових просторів та інші процедури попередньої обробки, які є необхідними перед подачею даних до нейронної мережі. Бібліотека підтримує оптимізовані обчислення та може використовувати апаратне прискорення, що дозволяє обробляти великі набори зображень у відносно короткий час [49].

Для роботи з числовими масивами та матрицями використовується бібліотека NumPy, яка є базовим інструментом для наукових обчислень у Python. NumPy забезпечує ефективну реалізацію операцій над багатовимірними масивами даних, що є особливо важливим при роботі з піксельними значеннями зображень. Використання цієї бібліотеки дозволяє значно пришвидшити обчислення, оскільки більшість операцій реалізовані на рівні оптимізованих C-бібліотек. NumPy широко використовується у більшості сучасних фреймворків машинного навчання, включаючи TensorFlow та PyTorch.

Для обробки табличних даних та роботи з метаданими датасету використовується бібліотека Pandas, яка надає зручні структури даних для зберігання та аналізу інформації. З її допомогою можна ефективно виконувати фільтрацію, сортування та групування даних, а також аналізувати статистичні

характеристики набору зображень. Це дозволяє контролювати баланс класів у датасеті, аналізувати кількість прикладів для кожної категорії та підготовлювати дані до процесу навчання моделей.

Для візуалізації результатів дослідження використовується бібліотека Matplotlib, яка дозволяє будувати різноманітні графіки та діаграми. За допомогою Matplotlib можна відображати динаміку зміни функції втрат під час навчання моделі, графіки точності, матриці невідповідностей та інші показники, що характеризують ефективність роботи алгоритмів. Використання засобів візуалізації є важливим для аналізу результатів експериментів та порівняння різних моделей глибокого навчання [50].

Таким чином, використання зазначених бібліотек забезпечує повний набір інструментів для підготовки, обробки та аналізу даних у задачі класифікації зображень. Їх інтеграція з фреймворками глибокого навчання дозволяє ефективно реалізувати систему автоматичного визначення хвороб рослин на основі аналізу зображень (див. таблиця 2.1).

Таблиця 2.1 - Порівняння бібліотек для реалізації моделі навчання системи

Бібліотека	Основне призначення	Ключові можливості	Використання у проєкті
OpenCV	Комп'ютерний зір та обробка зображень	Масштабування зображень, фільтрація шуму, перетворення кольорових просторів, сегментація, детекція об'єктів	Попередня обробка зображень листя, зміна розміру, нормалізація, аугментація
NumPy	Числові обчислення та робота з масивами	Обробка багатовимірних масивів, лінійна алгебра, математичні операції	Представлення зображень у вигляді числових масивів та швидкі обчислення

Продовження таблиці 2.1

Pandas	Аналіз та обробка табличних даних	Робота з таблицями, фільтрація, групування, статистичний аналіз	Аналіз структури датасету, баланс класів, підготовка метаданих
Matplotlib	Візуалізація даних	Побудова графіків, діаграм, гістограм, матриць невідповідностей	Візуалізація результатів навчання моделей та оцінки якості

Таким чином, використання зазначених бібліотек забезпечує повний набір інструментів для підготовки, обробки та аналізу даних у задачі класифікації зображень. Їх інтеграція з фреймворками глибокого навчання дозволяє ефективно реалізувати систему автоматичного визначення хвороб рослин на основі аналізу зображень.

2.6 Висновки до другого розділу

У другому розділі було проведено аналіз технологій та методів реалізації системи класифікації хвороб рослин за зображеннями. Сформульовано постановку задачі дослідження та визначено основні етапи обробки даних, включаючи попередню підготовку зображень, навчання моделей та оцінювання їх якості. Окрім цього, проаналізовано сучасні програмні засоби реалізації систем глибокого навчання. Визначено доцільність використання мови програмування Python, фреймворків TensorFlow та PyTorch, а також бібліотек комп'ютерного зору і обробки даних, зокрема OpenCV, NumPy, Pandas та Matplotlib. Застосування зазначених інструментів дозволяє ефективно реалізувати повний цикл розробки системи класифікації зображень — від підготовки датасету до оцінювання якості моделей та вибору найбільш ефективної архітектури для подальшого використання.

3 ДОСЛІДЖЕННЯ ТА РОЗРОБКА МОДЕЛЕЙ ГЛИБИННОГО НАВЧАННЯ ДЛЯ КЛАСИФІКАЦІЇ ХВОРОБ РОСЛИН

Розробка моделей глибокого навчання для класифікації хвороб рослин спрямована на створення ефективної системи автоматичного аналізу зображень листя. Використання методів комп'ютерного зору дозволяє визначати характерні візуальні ознаки захворювань та виконувати їх автоматичне розпізнавання. Такий підхід забезпечує можливість швидкої діагностики стану рослин та може застосовуватися для підвищення ефективності аграрного виробництва. Загальну структуру взаємодії користувача із системою доцільно представити за допомогою діаграми варіантів використання (див. рисунок 3.1).

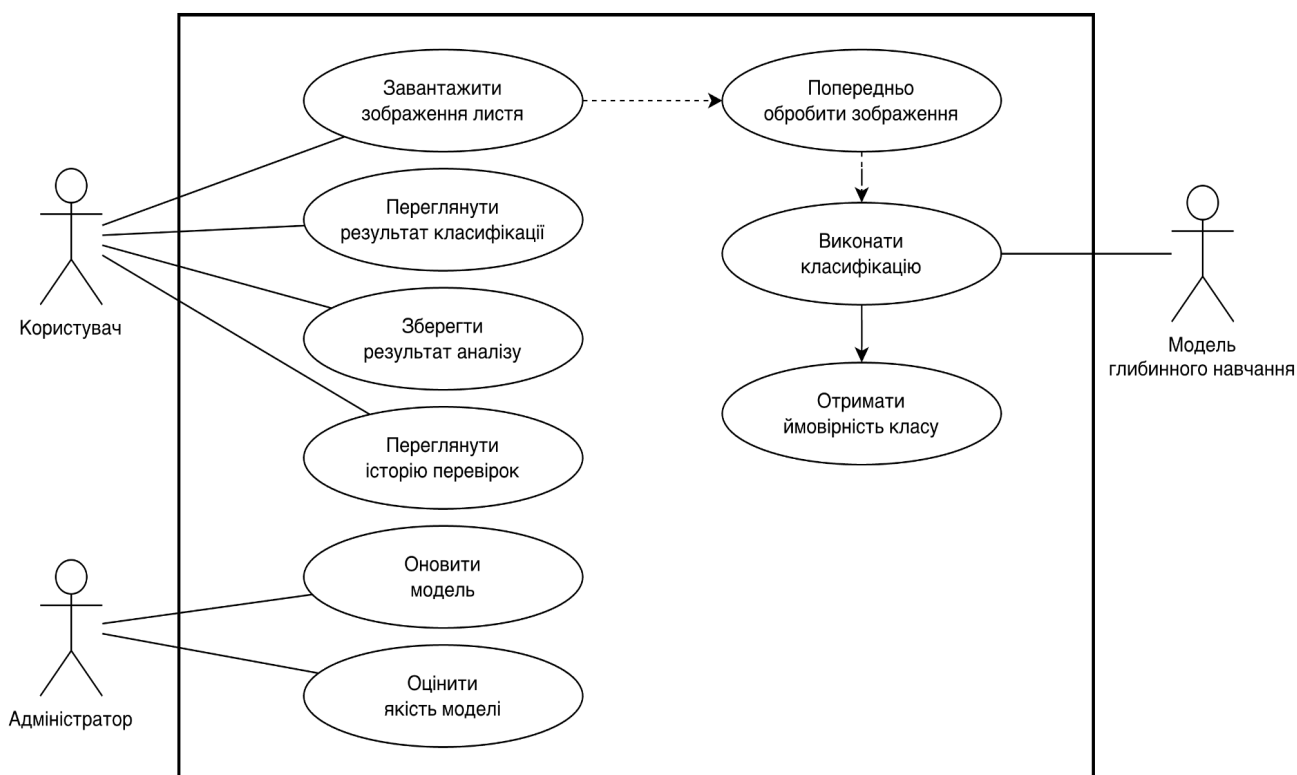


Рисунок 3.1 – Діаграма основних варіантів використання системи класифікації хвороб рослин

Дослідження передбачає побудову та навчання моделей глибокого навчання на основі набору зображень рослин із відповідними анотаціями. Особлива увага

приділяється застосуванню згорткових нейронних мереж та використанню попередньо навчених архітектур у межах трансферного навчання. Використання таких підходів дозволяє ефективно виділяти інформативні ознаки зображень та підвищувати точність класифікації навіть при обмеженому обсязі навчальних даних. Послідовність взаємодії між користувачем, модулем обробки зображень та моделлю класифікації може бути представлена за допомогою UML-діаграми послідовності (див. рисунок 3.2).

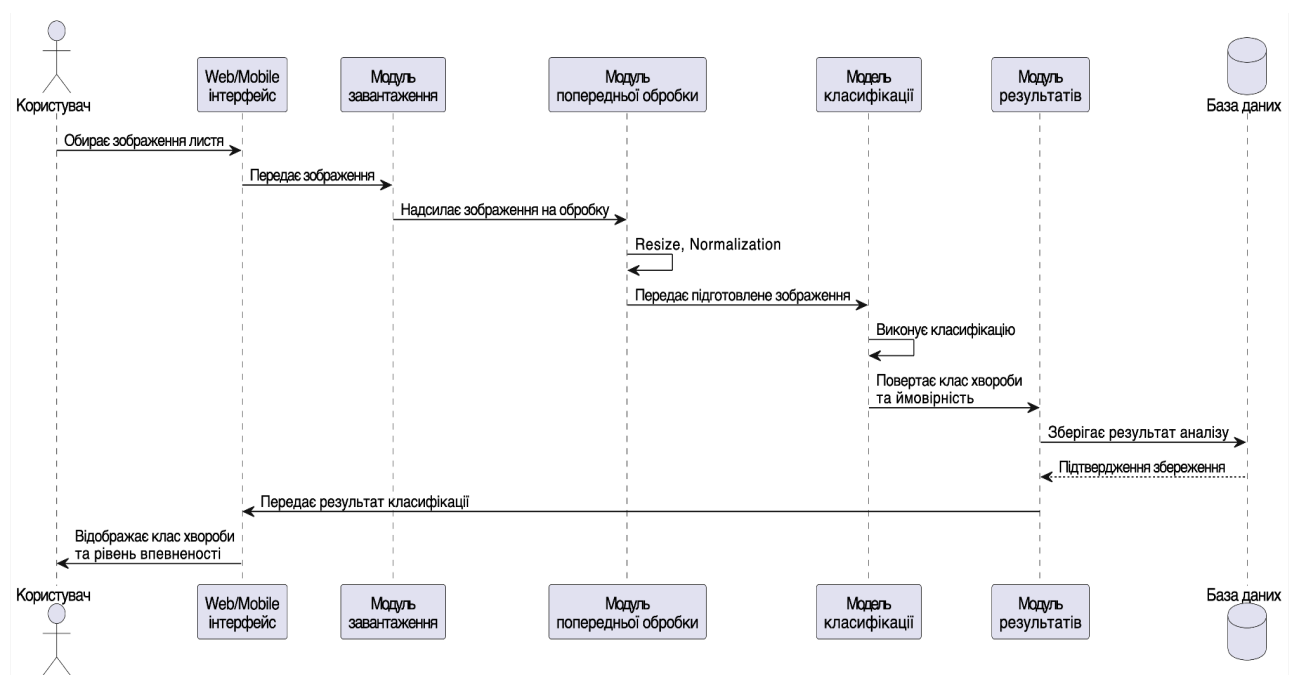


Рисунок 3.2 – Діаграма послідовності роботи системи класифікації зображень

Архітектура програмної системи включає модуль завантаження та попередньої обробки зображень, модуль глибинного навчання, компонент оцінювання результатів класифікації та інтерфейс користувача. Взаємозв'язок основних компонентів системи доцільно відобразити на загальній структурній діаграмі системи (див. рисунок 3.3).

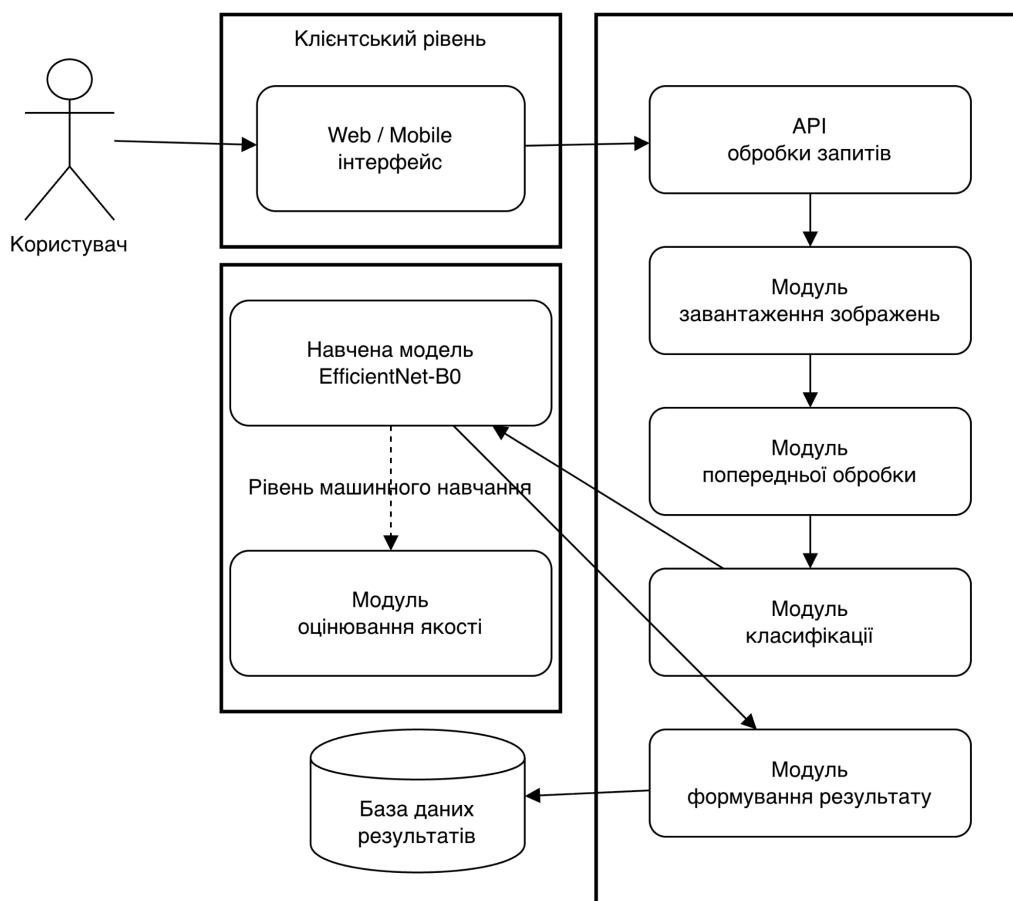


Рисунок 3.3 – Загальна архітектура системи класифікації хвороб рослин

Отримані результати дослідження дозволяють визначити найбільш ефективні архітектури моделей для задачі класифікації хвороб рослин, а також оцінити їх продуктивність за основними показниками якості. Реалізація та експериментальна перевірка моделей створює основу для подальшого впровадження систем автоматичного моніторингу стану рослин на основі методів штучного інтелекту. Основні етапи проходження даних у системі — від завантаження зображення до отримання результату класифікації — можуть бути додатково представлені у вигляді блок-схеми алгоритму роботи системи (див.рисунок 3.4).

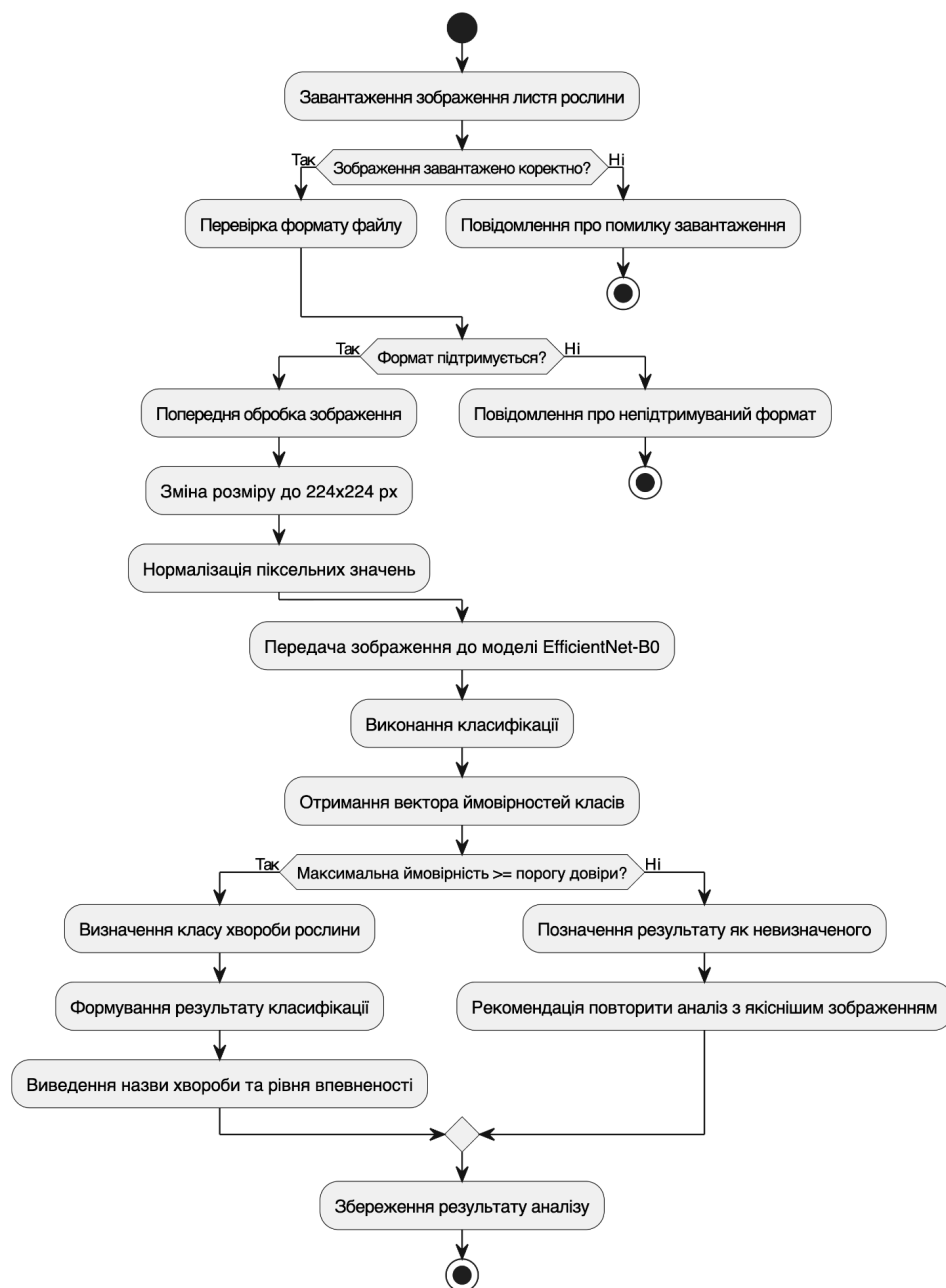


Рисунок 3.4 – Блок-схема процесу класифікації хвороб рослин за зображенням

Результати дослідження дозволяють визначити найбільш ефективні архітектури моделей для задачі класифікації хвороб рослин, а також оцінити їх продуктивність за основними показниками якості. Реалізація та експериментальна перевірка моделей створює основу для подальшого впровадження систем автоматичного моніторингу стану рослин на основі методів штучного інтелекту.

3.1 Формування та підготовка датасету

Якість та структура навчальних даних відіграють ключову роль у побудові ефективних моделей глибокого навчання. Для розв'язання задачі класифікації хвороб рослин було використано відкритий набір даних із платформи Kaggle, сформований на основі датасету PlantVillage. Цей набір містить велику кількість зображень листя різних сільськогосподарських культур із відповідними анотаціями, що вказують на тип захворювання або здоровий стан рослини. Використання такого датасету дозволяє навчати моделі розпізнавати характерні візуальні ознаки ураження рослин (див. таблицю 3.1).

Таблиця 3.1 - Характеристика даних

Характеристика	Опис
Назва датасету	PlantVillage (Kaggle Dataset)
Джерело даних	Платформа Kaggle
Тип даних	Зображення листя рослин
Формат файлів	JPG / PNG
Кількість зображень	≈ 54 000 зображень
Кількість класів	38 класів (здорові рослини та різні хвороби)
Тип задачі	Багатокласова класифікація зображень
Роздільна здатність зображень	Різна, приведена до стандартного розміру (224×224 px)
Основні ознаки (features)	колір листя, текстура, форма плям, уражені ділянки, структура поверхні
Цільовий атрибут (label)	клас захворювання рослини
Методи попередньої обробки	Resize, Normalization, Data Augmentation
Розподіл даних	Train – 70 %, Validation – 15 %, Test – 15 %

Продовження таблиці 3.1

Тип анотації	Класифікаційна мітка (назва хвороби)
Область застосування	Автоматичне виявлення хвороб рослин

В додатку Б таблиця Б.1 наведено структуру класів датасету PlantVillage, що використовується для задачі класифікації хвороб рослин. Датасет містить зображення листя різних культур, які поділяються на класи відповідно до типу захворювання або стану здорової рослини.

Датасет містить 38 класів, що відповідають різним поєднанням культур та захворювань. Найбільшу кількість класів представлено для рослини Tomato, оскільки томати мають значну кількість поширених захворювань, які добре задокументовані в агрономічних дослідженнях. Наявність окремих класів для здорових рослин дозволяє моделі навчитися відрізняти уражене листя від нормального стану рослини, що є важливим для практичного застосування систем автоматичної діагностики (див. таблицю 3.2).

Таблиця 3.2 - Основних характеристик зображень

Характеристика	Значення / Опис
Тип даних	Зображення листя рослин
Формат файлів	JPEG / JPG
Загальна кількість зображень	≈ 54 000
Кількість класів	38
Тип задачі	Багатокласова класифікація зображень
Початкова роздільна здатність	Різна (приблизно 256×256 – 512×512 px)
Роздільна здатність після обробки	224×224 px
Кольоровий простір	RGB (3 канали)

Продовження таблиці 3.2

Глибина кольору	24 біти
Тип ознак (features)	колір листя, текстура поверхні, форма та розмір плям, структура уражених ділянок
Цільовий атрибут (label)	клас захворювання рослини
Методи попередньої обробки	масштабування (Resize), нормалізація (Normalization), аугментація зображень
Методи аугментації	повороти, горизонтальне віддзеркалення, зміна яскравості, масштабування
Розподіл даних	Train – 70 %, Validation – 15 %, Test – 15 %
Тип анотації	категоріальна мітка класу

Ця таблиця описує основні характеристики зображень у датасеті, що використовуються під час навчання моделей глибокого навчання для класифікації хвороб рослин.

Кількість зображень наведених в таблиці 3.2 орієнтовно на основі загального розміру датасету PlantVillage. Такий розподіл даних є типовим для задач машинного навчання і дозволяє забезпечити коректну оцінку здатності моделі узагальнювати знання на нових зображеннях.

Перед початком навчання моделей було виконано підготовку даних, що включала структурування зображень за класами та перевірку коректності анотацій. Зображення були згруповані у відповідні директорії відповідно до категорій хвороб, що дозволяє зручно використовувати їх у процесі навчання нейронних мереж. Також було проведено аналіз структури датасету, визначено кількість класів та кількість прикладів у кожному класі, що дозволяє оцінити баланс даних (див. рисунок 3.5).



Рисунок 3.5 - Підготовка даних для навчання моделі

Наступним етапом стала підготовка зображень до використання у моделях глибокого навчання. Зображення були приведені до однакової роздільної здатності, що відповідає вимогам обраних архітектур нейронних мереж. Крім того, було виконано нормалізацію значень пікселів та застосовано методи аугментації даних, зокрема повороти, віддзеркалення та незначні зміни яскравості. Такі операції дозволяють збільшити різноманітність навчальної вибірки та підвищити стійкість моделей до варіацій умов зйомки.

Після завершення етапу підготовки даних датасет було розділено на навчальну, валідаційну та тестову вибірки. Такий поділ дозволяє коректно оцінити здатність моделі узагальнювати знання на нових зображеннях, що не використовувалися під час навчання. Отриманий підготовлений датасет слугує основою для проведення подальших експериментів із моделями глибокого навчання.

3.2 Реалізація моделей глибинного навчання

Для дослідження ефективності різних підходів до класифікації хвороб рослин було реалізовано систему автоматичного аналізу зображень на основі моделей глибинного навчання. Реалізація програмної частини здійснювалася з використанням фреймворку TensorFlow/Keras та сучасних методів трансферного навчання для попередньо навчених архітектур. Основною метою розробки було створення системи, яка забезпечує високу точність класифікації, стабільність роботи та можливість подальшої інтеграції у прикладні програмні рішення для аграрного сектору.

У системі було реалізовано декілька моделей глибинного навчання, зокрема базову CNN, VGG16, ResNet50, EfficientNet та Vision Transformer (ViT), які відрізняються структурою архітектури та принципами обробки зображень. Усі моделі навчалися на одному наборі даних та оцінювалися за однаковими метриками якості, що дозволило провести коректне порівняння їх ефективності. Для взаємодії користувача із системою було розроблено клієнтський інтерфейс, який забезпечує можливість завантаження зображення листа рослини та отримання результату класифікації. Загальний вигляд реалізованого інтерфейсу системи наведено на рисунку 3.6.

Усі моделі навчалися на одному й тому самому датасеті та оцінювалися за однаковими метриками якості, що забезпечує коректність порівняння результатів (див. таблицю 3.3).

Таблиця 3.3 – Результати тестування моделей глибинного навчання

Модель	Accuracy	Precision	Recall	F1-score	Час навчання
Базова CNN	0.914	0.908	0.905	0.906	45 хв

Продовження таблиці 3.3

VGG16 (Transfer Learning)	0.962	0.959	0.958	0.958	1.8 год
ResNet50	0.978	0.972	0.971	0.971	2.1 год
EfficientNet-B0	0.981	0.980	0.979	0.979	1.5 год
Vision Transformer (ViT)	0.977	0.975	0.974	0.974	2.8 год

1. Завантаження зображення

plants_dataset.zip
24.6 MB
 Змінити файл

Попередній перегляд

Файл містить: [128](#) зображень

2. Виберіть модель

EfficientNetB0 (натренована модель) ▼

Класифікувати

3. Результат класифікації

Аналіз завершено

Успішно класифіковано: 128/128 зображень

Точність моделі: **94.12%**

Підсумок результатів

Клас хвороби	Кількість	Відсоток
● Борошниста роса	45	35.16%
● Іржа	28	21.88%
● Альтернاریоз	22	17.19%
● Септоріоз	18	14.06%
● Здорова рослина	15	11.72%

i Результати показані для вибраної моделі.

Рисунок 3.6 – Клієнтський веб інтерфейс системи класифікації хвороб рослин

Отримані результати показали, що всі реалізовані моделі забезпечують високий рівень точності класифікації, проте найкращі результати

продемонструвала модель EfficientNet-B0. Вона забезпечила найвищі значення Accuracy та F1-score при відносно меншому часі навчання та меншій обчислювальній складності порівняно з VGG16, ResNet50 та Vision Transformer. Завдяки оптимізованому масштабуванню архітектури EfficientNet дозволяє ефективно використовувати обчислювальні ресурси без суттєвого зниження продуктивності.

Таким чином, модель EfficientNet-B0 була обрана як основна архітектура для подальшого використання у системі автоматичної класифікації хвороб рослин.

3.3 Налаштування та навчання моделей

Навчання моделей глибокого навчання виконувалося із використанням однакових параметрів для забезпечення коректного порівняння результатів. Усі моделі навчалися на підготовленому датасеті PlantVillage із застосуванням трансферного навчання та fine-tuning останніх шарів нейронних мереж.

Таблиця 3.4 – Основні параметри навчання моделей

Параметр	Значення
Оптимізатор	Adam
Learning Rate	0.001 / 0.0001
Batch Size	32
Кількість епох	25–30
Функція втрат	Categorical Crossentropy
Callbacks	EarlyStopping, ModelCheckpoint,
Апаратне прискорення	GPU (CUDA)
Тип навчання	Transfer Learning + Fine-Tuning

Як функцію оптимізації було використано алгоритм Adam optimizer, який забезпечує стабільну збіжність та ефективно оновлення ваг моделі під час навчання. Початкове значення learning rate становило 0.001, а при fine-tuning зменшувалося до 0.0001 для більш точного налаштування параметрів.

Під час навчання використовувався розмір пакета (batch size) 32, що забезпечує баланс між швидкістю навчання та використанням оперативної пам'яті GPU. Кількість епох (epochs) становила 25–30 залежно від моделі та стабільності процесу навчання.

Для запобігання перенавчанню застосовувалися механізми callbacks та Early Stopping. Early Stopping дозволяв автоматично завершувати навчання у випадку відсутності покращення значення validation loss протягом декількох епох. Також використовувався ModelCheckpoint для збереження найкращої версії моделі та ReduceLROnPlateau для автоматичного зменшення learning rate при уповільненні покращення результатів.

3.4 Аналіз результатів класифікації

За результатами експериментального дослідження найкращі показники продемонструвала модель EfficientNet-B0, яка забезпечила найвище значення Accuracy та F1-score при меншій обчислювальній складності порівняно з іншими архітектурами. Модель показала стабільну роботу на тестовій вибірці та кращу здатність до узагальнення нових зображень.

Базова CNN характеризувалася швидким навчанням та простою архітектурою, проте поступалася сучасним моделям за точністю класифікації. VGG16 забезпечила високі результати, однак мала велику кількість параметрів та потребувала більше обчислювальних ресурсів. ResNet50 продемонструвала стабільне навчання завдяки використанню skip-connections, що дозволило уникнути деградації точності при збільшенні глибини мережі. Vision Transformer

показав конкурентні результати, проте вимагав більшого часу навчання та значних обчислювальних ресурсів.

Використання transfer learning суттєво покращило результати всіх моделей. Попередньо навчені ваги дозволили скоротити час навчання та підвищити точність класифікації навіть при обмеженому обсязі навчальних даних. Fine-tuning останніх шарів моделей забезпечив адаптацію архітектур до специфіки датасету PlantVillage та дозволив покращити якість розпізнавання хвороб рослин.

Таким чином, модель EfficientNet-B0 була обрана як основна для подальшого використання у системі автоматичної класифікації хвороб рослин завдяки високій точності, ефективному використанню ресурсів та стабільності роботи.

3.5 Практичне застосування розробленої системи

Розроблена система класифікації хвороб рослин може бути використана в аграрному секторі для автоматизованого моніторингу стану сільськогосподарських культур. Використання моделей глибинного навчання дозволяє оперативно виявляти ознаки захворювань на ранніх етапах розвитку, що сприяє зменшенню втрат урожаю та оптимізації використання засобів захисту рослин. Такий підхід може застосовуватися у фермерських господарствах, тепличних комплексах та системах точного землеробства.

Практична реалізація системи передбачає можливість її інтеграції у web- або mobile-застосунок. У такому випадку користувач отримує можливість завантажувати зображення листя рослин через камеру смартфона або вебінтерфейс та автоматично отримувати результат класифікації. Подальший розвиток системи може включати створення серверної інфраструктури для централізованого навчання моделей, зберігання результатів аналізу та формування рекомендацій щодо обробки рослин.

Перспективним напрямом є інтеграція системи з IoT-пристроями та засобами автоматизованого моніторингу аграрних об'єктів. Використання дронів, камер спостереження та мобільних сенсорних платформ дозволить виконувати

безперервний аналіз стану рослин у реальному часі. Це створює основу для побудови інтелектуальних систем підтримки прийняття рішень у сільському господарстві.

Наукова цінність роботи полягає у дослідженні ефективності сучасних архітектур глибокого навчання для задач класифікації хвороб рослин та порівняльному аналізі їх продуктивності. Отримані результати можуть бути використані для подальших досліджень у галузі комп'ютерного зору, оптимізації моделей глибокого навчання та розробки інтелектуальних систем аграрного моніторингу.

3.6 Висновки до третього розділу

У третьому розділі було проведено дослідження та реалізацію моделей глибокого навчання для класифікації хвороб рослин за зображеннями. Виконано формування та підготовку датасету, реалізовано архітектури CNN, VGG16, ResNet50, EfficientNet та Vision Transformer, а також проведено їх навчання та тестування на однакових наборах даних.

У процесі експериментального дослідження було виконано порівняльний аналіз моделей за метриками Accuracy, Precision, Recall та F1-score. Отримані результати показали, що модель EfficientNet-B0 забезпечує найкраще співвідношення між точністю класифікації, стійкістю роботи та обчислювальною ефективністю.

Також було розроблено загальну архітектуру системи, UML-діаграми та клієнтський інтерфейс для взаємодії користувача із системою класифікації. Отримані результати підтверджують доцільність використання методів глибокого навчання для автоматизованої діагностики хвороб рослин та створюють основу для подальшого розвитку інтелектуальних систем аграрного моніторингу.

4. ОХОРОНА ПРАЦІ ТА БЕЗПЕКА В НАДЗВИЧАЙНИХ СИТУАЦІЯХ

4.1 Питання щодо охорони праці

Тема кваліфікаційної роботи освітнього рівня «Магістр» присвячена дослідженню та розробці моделей глибинного навчання для класифікації хвороб рослин за зображеннями. Тому доцільно розглянути питання охорони праці під час роботи з комп'ютерними системами, засобами обробки та аналізу даних, а також організації безпечних умов праці при використанні програмного забезпечення та обчислювальної техніки. Особливу увагу слід приділити забезпеченню безпечної роботи користувачів із персональними комп'ютерами, дотриманню санітарно-гігієнічних вимог до робочого місця та зниженню негативного впливу тривалої роботи за комп'ютером, оскільки розроблювана система передбачає інтенсивне використання засобів комп'ютерної техніки та програмного забезпечення для навчання і тестування моделей глибинного навчання.

4.1.1 Охорона праці під час роботи з комп'ютерними системами та засобами обробки даних

Під час розробки та тестування моделей глибинного навчання для класифікації хвороб рослин основна частина робіт виконується із використанням персональних комп'ютерів, графічних процесорів та спеціалізованого програмного забезпечення для обробки даних. У зв'язку з цим особливого значення набуває дотримання вимог охорони праці під час роботи з комп'ютерними системами та засобами обробки даних. Організація безпечних умов праці повинна здійснюватися відповідно до Закону України «Про охорону праці», Кодексу законів про працю України та чинних санітарно-гігієнічних норм [51], [52].

Робоче місце користувача комп'ютерної техніки повинно відповідати вимогам ергономіки та забезпечувати комфортні умови праці. Згідно з ДСанПіН 3.3.2-007-98, приміщення для роботи з персональними комп'ютерами повинні бути

обладнані належною системою освітлення, вентиляції та кондиціонування повітря [5]. Освітлення робочої зони має бути достатнім для зниження навантаження на органи зору та відповідати вимогам ДБН В.2.5-28:2018 [56]. Неправильне розташування монітора, недостатній рівень освітлення або тривала безперервна робота за комп'ютером можуть призводити до зорової втоми, головного болю, погіршення концентрації уваги та розвитку професійних захворювань.

Під час роботи із засобами обробки даних працівник зазнає впливу ряду небезпечних та шкідливих факторів. До основних факторів належать статичне навантаження на опорно-руховий апарат, перенапруження органів зору, нервово-емоційне навантаження, а також вплив електромагнітного випромінювання від комп'ютерного обладнання. Для мінімізації негативного впливу цих факторів необхідно дотримуватися регламентованого режиму праці та відпочинку, робити регулярні перерви під час роботи за комп'ютером та забезпечувати правильне розташування елементів робочого місця [55].

Особливу увагу слід приділити електробезпеці та пожежній безпеці під час експлуатації комп'ютерного обладнання. Усі технічні засоби повинні бути справними та відповідати вимогам безпечної експлуатації електроустановок. Забороняється використання пошкоджених кабелів живлення, несправних мережевих фільтрів або обладнання із порушеною ізоляцією. Робочі приміщення повинні бути оснащені засобами пожежогасіння та системами аварійного відключення електроживлення [54].

Таким чином, забезпечення безпечних умов праці під час роботи з комп'ютерними системами та засобами обробки даних є важливою складовою організації процесу розробки моделей глибинного навчання. Дотримання вимог охорони праці, санітарно-гігієнічних норм та правил експлуатації комп'ютерної техніки дозволяє знизити негативний вплив виробничих факторів на працівника та підвищити ефективність виконання робіт.

4.1.2 Забезпечення безпечних умов праці при використанні комп'ютерної техніки та програмного забезпечення

Безпечні умови праці при використанні комп'ютерної техніки та програмного забезпечення є важливою складовою ефективною організації робочого процесу під час розробки та тестування моделей глибокого навчання. Робота із сучасними програмними засобами обробки даних передбачає тривале використання персональних комп'ютерів, серверного обладнання та графічних прискорювачів, що вимагає дотримання нормативних вимог охорони праці та технічної безпеки [51], [55].

Робоче місце користувача повинно бути організоване відповідно до ергономічних вимог. Висота робочого столу та крісла має забезпечувати правильне положення тіла працівника під час роботи. Монітор повинен розташовуватися на відстані 60–70 см від очей користувача, а верхня межа екрана — на рівні очей або трохи нижче. Клавіатура та маніпулятор типу «миша» повинні розміщуватися таким чином, щоб мінімізувати навантаження на кисті рук та шийний відділ хребта [55].

Важливим фактором забезпечення безпечних умов праці є підтримання оптимального мікроклімату в приміщенні. Температура повітря, рівень вологості та швидкість руху повітря повинні відповідати санітарно-гігієнічним нормам для приміщень із комп'ютерною технікою. Під час роботи високопродуктивних GPU та серверних компонентів відбувається значне тепловиділення, тому необхідно забезпечити ефективну систему вентиляції та охолодження обладнання [55], [56].

Особливу увагу необхідно приділяти електробезпеці. Усі комп'ютерні системи та периферійні пристрої повинні бути заземлені та підключені через справні мережеві фільтри або джерела безперебійного живлення. Забороняється експлуатація обладнання з пошкодженими кабелями, несправними блоками живлення або ознаками перегріву. Для запобігання аварійним ситуаціям необхідно регулярно проводити технічну перевірку стану електромережі та комп'ютерної техніки [51], [54].

Під час використання програмного забезпечення важливим аспектом є забезпечення інформаційної безпеки та захисту даних. Системи обробки даних повинні бути захищені від несанкціонованого доступу, шкідливого програмного забезпечення та втрати інформації. Для цього рекомендується використовувати антивірусні засоби, механізми резервного копіювання даних, а також системи контролю доступу відповідно до вимог стандартів інформаційної безпеки [53], [58].

Таким чином, забезпечення безпечних умов праці при використанні комп'ютерної техніки та програмного забезпечення базується на комплексному дотриманні вимог ергономіки, електробезпеки, пожежної безпеки та інформаційного захисту. Реалізація цих заходів дозволяє підвищити надійність роботи комп'ютерних систем, знизити ризик виникнення аварійних ситуацій та забезпечити безпечну роботу користувачів під час розробки моделей глибокого навчання.

4.2 Питання щодо безпеки в надзвичайних ситуаціях

Використання високопродуктивного обчислювального обладнання, графічних прискорювачів та систем зберігання даних супроводжується ризиками виникнення аварійних ситуацій, пов'язаних із порушенням електроживлення, перегрівом обладнання, пожежною небезпекою або втратою даних. Тому питання аналізу небезпечних факторів, прогнозування потенційних загроз та забезпечення безпечної роботи комп'ютерних систем є невід'ємною складовою організації процесу розробки та експлуатації моделей глибокого навчання.

4.2.1 Аналіз небезпечних факторів під час експлуатації комп'ютерних систем та методи їх прогнозування

Під час експлуатації комп'ютерних систем та засобів обробки даних існує ряд небезпечних факторів, які можуть негативно впливати як на користувачів, так і

на працездатність програмно-апаратного комплексу. Особливо актуальним це є при виконанні ресурсомістких задач глибинного навчання, що супроводжуються значним навантаженням на центральний процесор, графічний прискорювач та систему електроживлення. Тому аналіз потенційних небезпек та прогнозування можливих аварійних ситуацій є важливою складовою забезпечення безпечної експлуатації комп'ютерних систем [51], [54].

До основних небезпечних факторів під час роботи комп'ютерних систем належать електричні, теплові, пожежонебезпечні та психофізіологічні фактори. Електричні фактори пов'язані з ризиком ураження електричним струмом унаслідок пошкодження ізоляції кабелів, несправності блоків живлення або порушення правил експлуатації електрообладнання. Особливу небезпеку становить використання великої кількості периферійних пристроїв та високопродуктивних GPU, які споживають значну потужність [51].

Теплові фактори виникають унаслідок перегріву компонентів комп'ютерної системи під час тривалого навчання моделей глибинного навчання. Підвищення температури процесора або графічного прискорювача може призводити до нестабільної роботи системи, пошкодження обладнання та виникнення пожежонебезпечних ситуацій. Основними причинами перегріву є недостатня вентиляція приміщення, несправність систем охолодження або надмірне навантаження на обчислювальні ресурси [55].

До психофізіологічних факторів належать перевтома, нервово-емоційне навантаження, зниження концентрації уваги та підвищена втомлюваність користувача під час тривалої роботи за комп'ютером. Виконання складних задач обробки даних та контролю процесу навчання моделей може супроводжуватися високим рівнем відповідальності та інтенсивним розумовим навантаженням. Недотримання режиму праці та відпочинку підвищує ризик професійного виснаження та виникнення помилок під час роботи з програмними системами [5].

Прогнозування небезпечних факторів базується на постійному моніторингу стану комп'ютерного обладнання та параметрів навколишнього середовища. Для контролю температурного режиму використовуються спеціалізовані програмні

засоби моніторингу стану CPU та GPU. Аналіз навантаження на систему дозволяє виявляти критичні режими роботи та своєчасно запобігати перегріву обладнання. Важливим елементом профілактики є регулярне технічне обслуговування комп'ютерної техніки, очищення систем охолодження та перевірка справності електромережі [56].

Для мінімізації ризику виникнення надзвичайних ситуацій необхідно забезпечити використання джерел безперебійного живлення, систем автоматичного захисту електромережі та засобів пожежогасіння. Приміщення, у яких експлуатуються комп'ютерні системи, повинні відповідати вимогам пожежної безпеки та бути оснащені засобами аварійного відключення електроживлення [54].

Таким чином, аналіз небезпечних факторів під час експлуатації комп'ютерних систем та методи їх прогнозування дозволяють своєчасно виявляти потенційні загрози та запобігати виникненню аварійних ситуацій. Дотримання вимог охорони праці, постійний контроль технічного стану обладнання та використання засобів моніторингу забезпечують безпечну та стабільну роботу систем обробки даних і моделей глибокого навчання.

4.2.2 Забезпечення безпеки користувачів і захисту даних в умовах надзвичайних ситуацій

Під час експлуатації комп'ютерних систем важливим аспектом є забезпечення безпеки користувачів та захисту даних в умовах надзвичайних ситуацій. Робота із системами обробки даних та моделями глибокого навчання супроводжується використанням значних обсягів інформації, програмного забезпечення та обчислювальних ресурсів, тому порушення стабільності роботи системи може призводити до втрати даних, пошкодження обладнання або виникнення аварійних ситуацій [53], [54].

До основних надзвичайних ситуацій під час роботи комп'ютерних систем належать перебої електроживлення, короткі замикання, пожежі, перегрів обладнання, збої програмного забезпечення та кіберінциденти. Особливу

небезпеку становить раптове вимкнення електроживлення під час виконання обчислювально складних задач, що може призвести до втрати результатів навчання моделей або пошкодження файлової системи. Для запобігання таким ситуаціям необхідно використовувати джерела безперебійного живлення (UPS), стабілізатори напруги та системи автоматичного резервного копіювання даних [51].

Важливим елементом захисту є забезпечення інформаційної безпеки та обмеження несанкціонованого доступу до програмної системи. Для цього застосовуються механізми автентифікації користувачів, системи контролю доступу, антивірусний захист та засоби шифрування даних. Захист інформації повинен здійснюватися відповідно до вимог Закону України «Про захист інформації в інформаційно-комунікаційних системах» та міжнародних стандартів інформаційної безпеки [53], [58]. У разі виникнення пожежі або іншої аварійної ситуації користувачі повинні діяти відповідно до затверджених інструкцій з евакуації та правил пожежної безпеки. Приміщення з комп'ютерною технікою повинні бути оснащені системами пожежної сигналізації, засобами пожежогасіння та аварійного відключення електроживлення. Особливу увагу необхідно приділяти серверному та високопродуктивному обладнанню, яке під час роботи створює значне теплове навантаження [54].

Для мінімізації ризику втрати інформації рекомендується здійснювати регулярне резервне копіювання результатів обробки даних та моделей глибокого навчання. Резервні копії повинні зберігатися на окремих носіях або у хмарних сховищах із контрольованим доступом. Це дозволяє забезпечити відновлення системи у випадку технічних збоїв, пошкодження обладнання або кібератак.

Таким чином, забезпечення безпеки користувачів і захисту даних в умовах надзвичайних ситуацій базується на комплексному підході, що включає технічний захист обладнання, інформаційну безпеку, резервування даних та дотримання правил пожежної й електробезпеки. Реалізація цих заходів дозволяє забезпечити стабільну та безпечну експлуатацію комп'ютерних систем під час роботи з моделями глибокого навчання.

ВИСНОВКИ

У результаті виконання кваліфікаційної роботи освітнього рівня «Магістр» на тему «Дослідження та розробка моделей глибокого навчання для класифікації хвороб рослин за зображеннями» отримано наступні результати.

У першому розділі проведено аналіз сучасних підходів до класифікації зображень та застосування методів машинного і глибокого навчання у задачах комп'ютерного зору. Розглянуто особливості автоматизованої діагностики хвороб рослин, проаналізовано класичні алгоритми машинного навчання та сучасні архітектури глибокого навчання, зокрема CNN, VGG16, ResNet50, EfficientNet та Vision Transformer. Досліджено підходи трансферного навчання та використання попередньо навчених моделей для задач класифікації зображень. Виконано порівняльний аналіз сучасних моделей глибокого навчання та визначено їх переваги й недоліки для задач автоматизованого аналізу зображень рослин.

У другому розділі описано технології та методи реалізації системи класифікації хвороб рослин. Проведено постановку задачі дослідження та формалізацію процесу класифікації зображень. Проаналізовано методи попередньої обробки даних, аугментації зображень та метрики оцінювання ефективності моделей. Обґрунтовано вибір програмних засобів реалізації, зокрема мови програмування Python, фреймворків TensorFlow та PyTorch, а також бібліотек OpenCV, NumPy та Pandas. Розроблено UML-діаграми, архітектуру системи та блок-схеми процесу класифікації, що дозволило сформувати цілісну структуру програмної системи.

У третьому розділі виконано формування та підготовку датасету PlantVillage для навчання моделей глибокого навчання. Реалізовано та протестовано моделі CNN, VGG16, ResNet50, EfficientNet-B0 та Vision Transformer із використанням методів трансферного навчання. Проведено навчання та експериментальне дослідження моделей за метриками Accuracy, Precision, Recall та F1-score. За результатами порівняльного аналізу встановлено, що модель EfficientNet-B0 забезпечує найкраще співвідношення між точністю класифікації, обчислювальною

ефективністю та стійкістю до перенавчання. Розроблено клієнтський інтерфейс системи класифікації хвороб рослин, який забезпечує завантаження зображень, вибір моделі та отримання результатів класифікації.

У межах роботи також розглянуто питання охорони праці та безпеки в надзвичайних ситуаціях під час експлуатації комп'ютерних систем та засобів обробки даних. Проаналізовано небезпечні фактори, пов'язані з використанням комп'ютерної техніки, та визначено основні заходи забезпечення безпечних умов праці, електробезпеки, пожежної безпеки та захисту даних.

Отримані результати експериментального дослідження підтвердили ефективність використання моделей глибокого навчання для автоматизованої класифікації хвороб рослин за зображеннями. У процесі тестування модель EfficientNet-B0 продемонструвала найкращі результати серед досліджуваних архітектур, забезпечивши точність класифікації (Accuracy) на рівні 98.1 %, значення Precision — 98.0 %, Recall — 97.9 % та F1-score — 97.9 %. При цьому модель характеризувалася меншою обчислювальною складністю та коротшим часом навчання порівняно з ResNet50 та Vision Transformer.

Практичне значення роботи полягає у розробці програмної системи, яка забезпечує автоматизовану класифікацію хвороб рослин на основі аналізу зображень листя та може бути використана як основа для створення інтелектуальних web- та mobile-застосунків у сфері аграрного моніторингу. Реалізована система дозволяє автоматизувати процес первинної діагностики захворювань рослин, зменшити час аналізу зображень та підвищити ефективність прийняття рішень у системах точного землеробства.

ПЕРЕЛІК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. Lyu S., Cheung R. C. C. (2023) Efficient Multiple Channels EEG Signal Classification Based on Hierarchical Extreme Learning Machine. *Sensors*. Vol. 23, No. 21. Art. 8976. DOI: <https://doi.org/10.3390/s23218976>.
2. Titkanlou M. K., Pham D. T., Mouček R. (2025) Classification of EEG Signal Using Deep Learning Architectures Based Motor-Imagery for an Upper-Limb Rehabilitation Exoskeleton. *SN Computer Science*. Vol. 6. Art. 193. DOI: <https://doi.org/10.1007/s42979-025-03743-6>.
3. Zhang Y., Ji X., Zhang S. (2023) Motor Imagery EEG Classification Based on Riemannian Geometry and CNN. *Brain Sciences*. Vol. 13, No. 4. DOI: <https://doi.org/10.3390/brainsci13040567>.
4. Dai G., Zhou J., Huang J., Wang N. (2021) Deep Learning for EEG Motor Imagery Classification Based on Multi-Scale Features. *Neural Computing and Applications*. Vol. 33. P. 8759–8773.
5. Dahiya Y., Solanki A. (2023) EEG-based Emotion Recognition Using Graph Convolutional Networks. *Biomedical Signal Processing and Control*. Vol. 84. Art. 104777.
6. Zhao X., Zhang H., Zhu G. (2023) A Novel Transfer Learning Framework for Motor Imagery EEG Classification. *IEEE Access*. Vol. 11. P. 42115–42128.
7. Marcos-Martínez D., Pérez-Velasco S., Martínez-Cagigal V., Santamaría-Vázquez E., Hornero R. (2025) Calibration-free Ocular artifact reduction in EEG signals using a montage-independent deep learning model. *Biomedical Signal Processing and Control*. T. 110. Ст. 108147. DOI: <https://doi.org/10.1016/j.bspc.2025.108147>.
8. Li Y., Liu Q., Fan S. (2022) A Deep Learning Approach for Motor Imagery EEG Classification Based on Residual Neural Networks. *IEEE Access*. Vol. 10. P. 11234–11245.
9. Zhang T., Chen W., Li M. (2024) Motor Imagery EEG Classification Using Graph Neural Networks. *Computers in Biology and Medicine*. Vol. 169. Art. 107823.

10. Kumar P., Singh A. (2024) EEG-Based Emotion Recognition Using Transformer and Convolutional Neural Networks. *Expert Systems with Applications*. Vol. 237. Art. 121435.
11. Altaheri H., Muhammad G., Alsulaiman M. (2023) A Spatio-Temporal Deep Learning Framework for EEG-Based Motor Imagery Classification. *Neural Networks*. Vol. 161. P. 33–47.
12. Ma R., Cao Y., Xie S. Q., Zhang M., Li J., Zhang Z.-Q. (2025) LGFCNN: A synergistic framework integrating graph-based spatial filter and lightweight CNN for SSVEP recognition. *Neurocomputing*. T. 656. Ct. 131561. DOI: <https://doi.org/10.1016/j.neucom.2025.131561>.
13. Sharma R., Gupta P. (2023) EEG Emotion Recognition Using LSTM with Attention Mechanism. *Biomedical Signal Processing and Control*. Vol. 82. Art. 104529.
14. Chen J., Liu Y., Wang X. (2024) A Novel RL-assisted Deep Learning Framework for Task-informative Signals Selection and Classification for Spontaneous BCIs. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*. Vol. 32. P. 1185–1196.
15. Ahmed K., Hassan M., Ali S. (2024) Optimal Channel Selection of Multiclass Motor Imagery Classification Based on Fusion Convolutional Neural Network with Attention Blocks. *Biomedical Signal Processing and Control*. Vol. 89. Art. 105812.
16. Venu K., Natesan P. (2023) Optimized Deep Learning Model Using Modified Whale's Optimization Algorithm for EEG Signal Classification. *Information Technology and Control*. Vol. 52, No. 3. P. 744–760. DOI: <https://doi.org/10.5755/j01.itc.52.3.33320>.
17. Chowdhury R. R., Muhammad Y., Adeel U. (2023) Enhancing Cross-Subject Motor Imagery Classification in EEG-Based Brain–Computer Interfaces by Using Multi-Branch CNN. *Sensors*. Vol. 23. Art. 7908. DOI: <https://doi.org/10.3390/s23187908>.
18. Li F., He F., Wang F. et al. (2020) A Novel Simplified Convolutional Neural Network Classification Algorithm of Motor Imagery EEG Signals Based on Deep

Learning. Applied Sciences. Vol. 10. Art. 1605. DOI: <https://doi.org/10.3390/app10051605>.

19. Ozelbas E., Tülay E. E., Ozekes S. (2024) Improving Cross-Subject Classification Performance of Motor Imagery Signals: A Data Augmentation-Focused Deep Learning Framework. Machine Learning: Science and Technology. Vol. 5. Art. 015021. DOI: <https://doi.org/10.1088/2632-2153/ad200c>.

20. Deng X., Zhang B., Yu N., Liu K., Sun K. (2021) Advanced TSGL-EEGNet for Motor Imagery EEG-Based Brain-Computer Interfaces. IEEE Access. Vol. 9. P. 25118–25131. DOI: <https://doi.org/10.1109/ACCESS.2021.3056088>.

21. Zhang K., Xu G., Han Z. et al. (2020) Data Augmentation for Motor Imagery Signal Classification Based on a Hybrid Neural Network. Sensors. Vol. 20. Art. 4485. DOI: <https://doi.org/10.3390/s20164485>.

22. Özdenizci O., Wang Y., Koike-Akino T., Erdoğan D. (2020) Learning Invariant Representations From EEG via Adversarial Inference. IEEE Access. Vol. 8. P. 27074–27084. DOI: <https://doi.org/10.1109/ACCESS.2020.2971600>.

23. Lomelin-Ibarra V. A., Gutierrez-Rodriguez A. E., Cantoral-Ceballos J. A. (2022) Motor Imagery Analysis from Extensive EEG Data Representations Using Convolutional Neural Networks. Sensors. Vol. 22. Art. 6093. DOI: <https://doi.org/10.3390/s22166093>.

24. Taghizadeh M., Vaez F., Faezipour M. (2024) EEG Motor Imagery Classification by Feature Extracted Deep 1D-CNN and Semi-Deep Fine-Tuning. IEEE Access. Vol. 12. P. 111265–111279. DOI: <https://doi.org/10.1109/ACCESS.2024.3430838>.

25. Li D., Liu P., Xia Y. (2023) A Novel Artifact Removal Strategy and Spatial Attention-based Multiscale CNN for MI Recognition. International Journal of Advanced Computer Science and Applications. Vol. 14, No. 9. P. 283–292.

26. Zhou B., Wang L., Xu W., Jiang C. (2024) Multi-Scale Convolutional Attention and Riemannian Geometry Network for EEG-Based Motor Imagery Classification. IEEE Access. Vol. 12. P. 79731–79741. DOI: <https://doi.org/10.1109/ACCESS.2024.3410036>.

27. Li L., Sun N. (2022) Attention-Based DSC-ConvLSTM for Multiclass Motor Imagery Classification. *Computational Intelligence and Neuroscience*. Vol. 2022. Article ID 8187009. DOI: <https://doi.org/10.1155/2022/8187009>.
28. Ha K.-W., Jeong J.-W. (2021) Temporal Pyramid Pooling for Decoding Motor-Imagery EEG Signals. *IEEE Access*. Vol. 9. P. 3112–3123. DOI: <https://doi.org/10.1109/ACCESS.2020.3047678>.
29. Abibullaev B., Dolzhikova I., Zollanvari A. (2020) A Brute-Force CNN Model Selection for Accurate Classification of Sensorimotor Rhythms in BCIs. *IEEE Access*. Vol. 8. P. 101014–101027. DOI: <https://doi.org/10.1109/ACCESS.2020.2997681>.
30. Megalingam R. K., Sankardas K. S., Manoharan S. K. (2024) An Empirical Model-Based Algorithm for Removing Motion-Caused Artifacts in Motor Imagery EEG Data for Classification Using an Optimized CNN Model. *Sensors*. Vol. 24. Art. 7690. DOI: <https://doi.org/10.3390/s24237690>.
31. Hanafy M. A., Yusufjonov S., SharafianArdakani P., Yusufjonov D., Rayguru M. M., Popa D. O. (2025) A Dual-Validation Framework for Temporal Robustness Assessment in Brain–Computer Interfaces for Motor Imagery. *Technologies*. T. 13, № 12. Ct. 595. DOI: <https://doi.org/10.3390/technologies13120595>.
32. Miao Z., Zhang X., Menon C. et al. (2023) Priming Cross-Session Motor Imagery Classification with A Universal Deep Domain Adaptation Framework. *arXiv*. DOI: <https://doi.org/10.48550/arXiv.2202.09559>.
33. Olza A., Soto D., Santana R. (2025) Domain Adaptation-enhanced searchlight: enabling classification of brain states from visual perception to mental imagery. *Brain Informatics*. T. 12. Ct. 17. DOI: <https://doi.org/10.1186/s40708-025-00263-0>.
34. Xia Y., Dong J., Li D. et al. (2023) An Adaptive Channel Selection and Graph ResNet Based Algorithm for Motor Imagery Classification. *International Journal of Advanced Computer Science and Applications*. Vol. 14, No. 5. P. 240–248.
35. Abdulkarim H., Al-Faiz M. Z. (2021) Online Multiclass EEG Feature Extraction and Recognition Using Modified Convolutional Neural Network Method.

International Journal of Electrical and Computer Engineering. Vol. 11, No. 5. P. 4016–4026. DOI: <https://doi.org/10.11591/ijece.v11i5.pp4016-4026>.

36. Padfield N., Ren J., Murray P., Zhao H. (2021) Sparse Learning of Band Power Features with Genetic Channel Selection for Effective Classification of EEG Signals. *Neurocomputing*. Vol. 463. P. 566–579. DOI: <https://doi.org/10.1016/j.neucom.2021.08.067>.

37. Singh A. K., Bianchi L. (2024) Encoding Temporal Information in Deep Convolution Neural Network. *Frontiers in Neuroergonomics*. Vol. 5. Art. 1287794. DOI: <https://doi.org/10.3389/fnrgo.2024.1287794>.

38. Huang B., Xu H., Yuan M. et al. (2022) Exploiting Asymmetric EEG Signals with EFD in Deep Learning Domain for Robust BCI. *Symmetry*. Vol. 14. Art. 2677. DOI: <https://doi.org/10.3390/sym14122677>.

39. Kocejko T., Matuszkiewicz N., Durawa P. et al. (2024) How Integration of a Brain-Machine Interface and Obstacle Detection System Can Improve Wheelchair Control via Movement Imagery. *Sensors*. Vol. 24. Art. 918. DOI: <https://doi.org/10.3390/s24030918>.

40. Hwang J., Park S., Chi J. (2023) Improving Multi-Class Motor Imagery EEG Classification Using Overlapping Sliding Window and Deep Learning Model. *Electronics*. Vol. 12. Art. 1186. DOI: <https://doi.org/10.3390/electronics12051186>.

41. Salami A., Andreu-Perez J., Gillmeister H. (2022) EEG-ITNet: An Explainable Inception Temporal Convolutional Network for Motor Imagery Classification. *IEEE Access*. Vol. 10. P. 36672–36687. DOI: <https://doi.org/10.1109/ACCESS.2022.3161489>.

42. Parchami J., Sarbishaei G. (2023) A Novel Scheme Based on Information Theory and Transfer Learning for Multi Classes Motor Imagery Decoding. *IET Signal Processing*. DOI: <https://doi.org/10.1049/sil2.12222>.

43. Roy A. M. (2022) An Efficient Multi-Scale CNN Model with Intrinsic Feature Integration for Motor Imagery EEG Subject Classification in Brain-Machine Interfaces. *Biomedical Signal Processing and Control*. Vol. 74. Art. 103496. DOI: <https://doi.org/10.1016/j.bspc.2022.103496>.

44. Zhang J., Li K. (2023) A Multi-View CNN Encoding for Motor Imagery EEG Signals. *Biomedical Signal Processing and Control*. Vol. 85. Art. 105063. DOI: <https://doi.org/10.1016/j.bspc.2023.105063>.
45. Hwaidi J. F., Chen T. M. (2022) Classification of Motor Imagery EEG Signals Based on Deep Autoencoder and Convolutional Neural Network Approach. *IEEE Access*. Vol. 10. P. 48071–48081. DOI: <https://doi.org/10.1109/ACCESS.2022.3171906>.
46. Zhang K., Robinson N., Lee S.-W., Guan C. (2021) Adaptive Transfer Learning for EEG Motor Imagery Classification with Deep Convolutional Neural Network. *Neural Networks*. Vol. 136. P. 1–10. DOI: <https://doi.org/10.1016/j.neunet.2020.12.013>.
47. Xie Y., Oniga S. (2023) Classification of Motor Imagery EEG Signals Based on Data Augmentation and Convolutional Neural Networks. *Sensors*. Vol. 23. Art. 1932. DOI: <https://doi.org/10.3390/s23041932>.
48. Ju C., Guan C. (2023) Tensor-CSPNet: A Novel Geometric Deep Learning Framework for Motor Imagery Classification. *IEEE Transactions on Neural Networks and Learning Systems*. Vol. 34, No. 12. P. 10955–10969. DOI: <https://doi.org/10.1109/TNNLS.2022.3172108>.
49. Mallat S., Hkiri E., Albarrak A. M., Louhichi B. (2025) A Synergy of Convolutional Neural Networks for Sensor-Based EEG Brain–Computer Interfaces to Enhance Motor Imagery Classification. *Sensors*. Vol. 25. Art. 443. DOI: <https://doi.org/10.3390/s25020443>.
50. Mwata-Velu T., Avina-Cervantes J. G., Ruiz-Pinales J. et al. (2022) Improving Motor Imagery EEG Classification Based on Channel Selection Using a Deep Learning Architecture. *Mathematics*. Vol. 10. Art. 2302. DOI: <https://doi.org/10.3390/math10132302>.
51. Закон України «Про охорону праці» : Закон України від 14.10.1992 № 2694-XII. URL: <https://zakon.rada.gov.ua/laws/show/2694-12> (дата звернення: 25.05.2026).

52. Кодекс законів про працю України : Закон України від 10.12.1971 № 322-VIII. URL: <https://zakon.rada.gov.ua/laws/show/322-08> (дата звернення: 25.05.2026).

53. Закон України «Про захист інформації в інформаційно-комунікаційних системах» : Закон України від 05.07.1994 № 80/94-ВР. URL: <https://zakon.rada.gov.ua/laws/show/80/94-%D0%B2%D1%80> (дата звернення: 25.05.2026).

54. Кодекс цивільного захисту України : Закон України від 02.10.2012 № 5403-VI. URL: <https://zakon.rada.gov.ua/laws/show/5403-17> (дата звернення: 25.05.2026).

55. ДСанПіН 3.3.2-007-98. Державні санітарні правила і норми роботи з візуальними дисплейними терміналами електронно-обчислювальних машин. Київ : МОЗ України, 1998. URL: <https://ips.ligazakon.net/document/REG455> (дата звернення: 25.05.2026).

56. ДБН В.2.5-28:2018. Природне і штучне освітлення. Київ : Мінрегіон України, 2018. URL: https://online.budstandart.com/ua/catalog/doc-page.html?id_doc=79885 (дата звернення: 25.05.2026).

57. ДСТУ ISO/IEC 25010:2016. Системна та програмна інженерія. Моделі якості систем та програмних засобів. Київ : ДП «УкрНДНЦ», 2016. URL: https://online.budstandart.com/ua/catalog/doc-page?id_doc=71810 (дата звернення: 25.05.2026).

58. ISO/IEC 27001:2022. Information security, cybersecurity and privacy protection — Information security management systems — Requirements. Geneva : International Organization for Standardization, 2022. URL: <https://www.iso.org/standard/27001> (дата звернення: 25.05.2026).

ДОДАТКИ

Апробація дослідження на конференції

УДК 621.326

Семенів М.–ст. гр. СНм-61

Тернопільський національний технічний університет імені Івана Пулюя

ДОСЛІДЖЕННЯ ТА РОЗРОБКА МОДЕЛЕЙ ГЛИБИННОГО НАВЧАННЯ ДЛЯ КЛАСИФІКАЦІЇ ХВОРОБ РОСЛИН ЗА ЗОБРАЖЕННЯМИ

Науковий керівник: к.т.н., доцент Боднарчук І. О.

Semeniv M.

Ternopil Ivan Puluj National Technical University

RESEARCH AND DEVELOPMENT OF DEEP LEARNING MODELS FOR PLANT DISEASE CLASSIFICATION USING IMAGES

Supervisor: PhD in Technical Sciences, Associate Professor Bodnarchuk I.

Ключові слова: глибинне навчання, класифікація зображень, хвороби рослин

Keywords: deep learning, image classification, plant diseases

Класифікація хвороб рослин на основі зображень є важливою задачею в сучасному аграрному секторі, оскільки своєчасне виявлення захворювань дозволяє зменшити втрати врожаю та підвищити ефективність сільського господарства. Візуальні ознаки ураження рослин, такі як зміна кольору, текстури та структури листя, можуть бути складними для точного аналізу людиною, особливо при великій кількості даних або на ранніх стадіях розвитку хвороби. У цьому контексті методи глибинного навчання демонструють високу ефективність, забезпечуючи автоматизоване виявлення складних патернів у зображеннях.

Моделі згорткових нейронних мереж (CNN), зокрема ResNet, EfficientNet, MobileNet та DenseNet, широко застосовуються для задач класифікації зображень рослин. Вони дозволяють автоматично витягувати інформативні ознаки без необхідності ручного конструювання характеристик. Глибокі архітектури здатні ефективно працювати з великою варіативністю даних, враховуючи різні умови освітлення, фон, ступінь ураження та види рослин. При цьому легковагові моделі, такі як MobileNet, є особливо перспективними для використання у мобільних або вбудованих системах, що дозволяє реалізувати практичні рішення безпосередньо в польових умовах.

Окрім класичних CNN, активно досліджуються гібридні підходи та моделі на основі трансформерів, які дозволяють краще враховувати глобальні залежності в зображеннях. Використання transfer learning є ключовим фактором підвищення якості моделей, оскільки дозволяє використовувати попередньо навчені ваги на великих датасетах і адаптувати їх до задачі класифікації хвороб рослин.

Експериментальні результати показують, що сучасні моделі глибинного навчання здатні досягати точності понад 90% на відкритих датасетах, таких як PlantVillage, при цьому використання ансамблевих підходів або комбінування моделей дозволяє додатково підвищити стабільність та узагальнювальну здатність системи. Основними метриками оцінювання виступають accuracy, F1-score та ROC-AUC, що забезпечує комплексний аналіз якості класифікації [1].

Незважаючи на високі результати, існують проблеми, пов'язані з узагальненням моделей на реальні умови, де зображення можуть містити шум, складний фон або перекриття об'єктів. Тому подальші дослідження спрямовані на підвищення робастності моделей, оптимізацію обчислювальних ресурсів та інтеграцію систем у реальні аграрні середовища. Розробка таких інтелектуальних систем відкриває можливості для створення ефективних інструментів моніторингу стану рослин та підтримки прийняття рішень у сільському господарстві [2].

Додатково слід відзначити, що сучасні підходи до класифікації хвороб рослин активно використовують методи аугментації даних, що дозволяють підвищити стійкість моделей до варіацій у зображеннях. Такі техніки, як випадкові обертання, масштабування, зміна яскравості та контрасту, імітують реальні умови зйомки та сприяють покращенню узагальнювальної здатності моделей. Окрім цього, застосування регуляризаційних методів, зокрема Dropout та Batch Normalization, дозволяє зменшити перенавчання та стабілізувати процес навчання глибоких нейронних мереж.

Важливим напрямом є також використання attention-механізмів, які дозволяють моделі фокусуватися на найбільш інформативних ділянках зображення, таких як уражені області листя. Це підвищує інтерпретованість результатів та дозволяє краще зрозуміти процес прийняття рішень моделлю. Окрім того, сучасні дослідження демонструють ефективність Vision Transformer (ViT) та їх гібридних варіантів у задачах аграрного комп'ютерного зору, де вони здатні перевершувати класичні CNN за рахунок врахування глобального контексту зображення [2]. Також значну увагу приділяють оптимізації моделей для використання в умовах обмежених ресурсів. Методи квантизації, прунингу та знань-дистиляції дозволяють зменшити розмір моделей та пришвидшити їх роботу без суттєвої втрати точності. Це є критично важливим для впровадження систем у мобільні додатки або edge-пристрої, що використовуються безпосередньо в польових умовах [3].

Важливим є не лише вибір моделі, але й узгоджена інтеграція всіх етапів обробки — від збору та очищення зображень до навчання, валідації та подальшого розгортання. Використання transfer learning дозволяє суттєво скоротити вимоги до обсягу навчальних даних, тоді як аугментація підвищує здатність моделей працювати в реальних умовах з варіативними вхідними даними. Оптимізаційні методи, такі як квантизація, прунинг і дистиляція знань, забезпечують можливість впровадження моделей у середовищах з обмеженими ресурсами без значної втрати якості.

У результаті формується не просто окрема модель, а повноцінна інтелектуальна система, здатна працювати в реальному часі, масштабуватись під різні культури та типи захворювань, а також адаптуватись до нових даних. Це відкриває перспективи створення доступних інструментів для аграріїв, які можуть використовуватись як у мобільних додатках, так і в автоматизованих системах моніторингу, підвищуючи точність діагностики, зменшуючи залежність від експертної оцінки та сприяючи більш ефективному управлінню сільськогосподарським виробництвом.

Література:

1. Dosovitskiy, A. et al. (2021). An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale. — ICLR.
2. Khan, A., Sohail, A., Zahoor, U., Qureshi, A. S. (2022). A survey of the recent architectures of deep convolutional neural networks. — Artificial Intelligence Review.
3. Zhang, Y., Liu, B., Zhang, X. (2023). Deep learning-based plant disease detection: A review of recent developments. — Computers and Electronics in Agriculture.

Структура класів датасету PlantVillage

Таблиця Б.1 - Структура класів датасету PlantVillage

№	Рослина	Клас (хвороба / стан)
1	Apple	Apple Scab
2	Apple	Black Rot
3	Apple	Cedar Apple Rust
4	Apple	Healthy
5	Blueberry	Healthy
6	Cherry	Powdery Mildew
7	Cherry	Healthy
8	Corn (Maize)	Cercospora Leaf Spot / Gray Leaf Spot
9	Corn (Maize)	Common Rust
10	Corn (Maize)	Northern Leaf Blight
11	Corn (Maize)	Healthy
12	Grape	Black Rot
13	Grape	Esca (Black Measles)
14	Grape	Leaf Blight
15	Grape	Healthy
16	Orange	Huanglongbing (Citrus Greening)
17	Peach	Bacterial Spot
18	Peach	Healthy
19	Pepper (Bell)	Bacterial Spot
20	Pepper (Bell)	Healthy
21	Potato	Early Blight
22	Potato	Late Blight

23	Potato	Healthy
24	Raspberry	Healthy
25	Soybean	Healthy
26	Squash	Powdery Mildew
27	Strawberry	Leaf Scorch
28	Strawberry	Healthy
29	Tomato	Bacterial Spot
30	Tomato	Early Blight
31	Tomato	Late Blight
32	Tomato	Leaf Mold
33	Tomato	Septoria Leaf Spot
34	Tomato	Spider Mites
35	Tomato	Target Spot
36	Tomato	Yellow Leaf Curl Virus
37	Tomato	Mosaic Virus
38	Tomato	Healthy