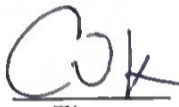




## КВАЛІФІКАЦІЙНА РОБОТА

на тему Метод автоматичної класифікації патологій листя рослин на основі згорткових нейронних мереж

Рівень вищої освіти другий (магістерський)  
Галузь знань 12 – Інформаційні технології  
Шифр і найменування  
Спеціальність 122 – Комп'ютерні науки  
Код і найменування  
Освітня програма Комп'ютерні науки  
Назва

Виконав: студент 2 курсу, група КНм-24-1  Валентин СОКОЛОВСЬКИЙ  
Курс, група виконавця Підпис Ім'я, ПРІЗВИЩЕ

Керівник: д.т.н., професор кафедри КН  Едуард МАНЗЮК  
Науковий ступінь, посада Підпис Ім'я, ПРІЗВИЩЕ

Нормоконтроль: к.т.н., доцент кафедри КН  Руслан БАГРІЙ  
Науковий ступінь, посада Підпис Ім'я, ПРІЗВИЩЕ

До захисту допускаю:

Зав. кафедри КН, д.т.н., професор  Олександр БАРМАК  
Підпис Ім'я, ПРІЗВИЩЕ

15 грудня 2025 р.

ХМЕЛЬНИЦЬКИЙ НАЦІОНАЛЬНИЙ УНІВЕРСИТЕТ

Факультет інформаційних технологій

Кафедра комп'ютерних наук

Освітній ступінь магістр

Галузь знань 12 – Інформаційні технології

Спеціальність 122 – Комп'ютерні науки

ЗАТВЕРДЖУЮ

Завідувач кафедри комп'ютерних наук



(підпис)

д.т.н., професор Олександр БАРМАК

«28» 08 2025 року

**ЗАВДАННЯ  
НА КВАЛІФІКАЦІЙНУ РОБОТУ**

1. Тема кваліфікаційної роботи: «Метод автоматичної класифікації патологій  
листя рослин на основі згорткових нейронних мереж»

2. Завдання видано студенту Валентину СОКОЛОВСЬКОМУ

(Ім'я, ПРІЗВИЩЕ)

3. Керівник роботи професор кафедри КН Едуард МАНЗЮК

(Ім'я, ПРІЗВИЩЕ)

4. Затверджені наказом університету від «25» 08 2025 р. № 65

5. Дата видачі завдання студенту: «28» 08 2025 р.

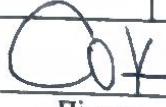
6. Зміст пояснювальної записки (перелік задач) та вихідні дані:

Мета роботи полягає у підвищенні точності розпізнавання та класифікації  
патологій листя сільськогосподарських рослин шляхом розробки методу з  
використанням згорткових нейронних мереж та механізмів регуляризації.

Перелік задач: проаналізувати існуючі підходи до автоматизованої діагностики  
захворювань рослин; розробити метод класифікації патологій листя з  
використанням згорткових нейронних мереж та регуляризації; створити  
архітектуру нейронної мережі для ефективного витягнення ознак із зображень  
листя рослин; реалізувати попередню обробку даних для підвищення  
узагальнювальної здатності моделі; провести експериментальне дослідження  
запропонованого методу.

7. Календарний план виконання кваліфікаційної роботи:

№	Назва етапів (розділів) кваліфікаційної роботи магістра	Термін виконання	Примітка
1	Вибір напрямку дослідження та узгодження теми кваліфікаційної роботи з керівником, складання календарного графіка виконання роботи	вересень 2025	Виконано
2	Ознайомлення з предметною областю, аналіз існуючих методів і моделей, формулювання мети та завдань дослідження, визначення об'єкта й предмета дослідження	вересень 2025	Виконано
3	Розробка методу чи моделі для вирішення обраного завдання, опис архітектури рішення	жовтень 2025	Виконано
4	Програмна реалізація методу чи моделі	жовтень 2025	Виконано
5	Дослідження ефективності та експериментальна перевірка результатів, порівняння з відомими підходами	листопад 2025	Виконано
6	Написання пояснювальної записки, оформлення відповідно до вимог, врахування зауважень керівника	листопад 2025	Виконано
7	Підготовка презентаційних матеріалів та попередній захист	листопад 2025	Виконано
8	Перевірка пояснювальної записки на відповідність вимогам оформлення (нормоконтроль) та перевірка на академічну доброчесність. Отримання відгуку керівника та рецензії.	грудень 2025	Виконано
9	Публічний захист кваліфікаційної роботи	грудень 2025	Виконано

Виконавець: студент групи КНм-24-1  Валентин СОКОЛОВСЬКИЙ  
 Група виконавця Підпис Ім'я, ПРІЗВИЩЕ

Керівник: д.т.н., проф. каф. КН  Едуард МАНЗЮК  
 Науковий ступінь, посада Підпис Ім'я, ПРІЗВИЩЕ

## Реферат

Кваліфікаційна робота магістра присвячена розробці методу класифікації патологій листя рослин за професійними категоріями з використанням машинного навчання.

**Актуальність теми.** Актуальність роботи обумовлена критичною необхідністю впровадження автоматизованих систем діагностики захворювань сільськогосподарських культур. Традиційні методи виявлення патологій, які базуються на візуальному огляді спеціалістами-агрономами, характеризуються високою трудомісткістю, потребують значних часових витрат та залежать від кваліфікації експерта.

Системи штучного інтелекту, зокрема методи глибокого навчання, створюють можливості для суттєвого підвищення швидкості та точності діагностування захворювань рослин. Автоматизація процесів розпізнавання дозволяє виявляти патології на ранніх стадіях розвитку, коли застосування захисних заходів є найбільш ефективним. Відповідно зменшується використання пестицидів, мінімізація економічних втрат від епідемій та покращенню загальної продуктивності сільського господарства.

Додатково, використання технологій машинного навчання допомагає вирішити проблему нестачі кваліфікованих фахівців у віддалених сільськогосподарських регіонах. Це підкреслює актуальність роботи як для практичного застосування в аграрному секторі, так і для наукових досліджень у галузі комп'ютерного зору та автоматизованого аналізу зображень.

**Мета роботи.** Мета роботи полягає у підвищенні точності розпізнавання та класифікації патологій листя сільськогосподарських рослин шляхом розробки методу з використанням згорткових нейронних мереж та механізмів регуляризації.

Задачі дослідження

- провести аналіз існуючих методів та підходів до діагностики захворювань рослин з використанням методів машинного та глибокого навчання;
- розробити метод класифікації патологій листя з використанням згорткових нейронних мереж та механізмів регуляризації;

– спроектувати архітектуру нейронної мережі для ефективного витягнення візуальних ознак із зображень листя;

– програмно реалізувати метод розпізнавання та класифікації патологій листя сільськогосподарських рослин з використанням згорткових нейронних мереж та механізмів регуляризації;

– провести експериментальне дослідження розробленого методу шляхом порівняння різних конфігурацій архітектури та оцінки їх точності класифікації патологій рослин.

**Об'єкт дослідження** – процес автоматизованої діагностики захворювань рослин на основі аналізу зображень листя.

**Предмет дослідження** – моделі, методи та засоби класифікації патологій рослин з використанням згорткових нейронних мереж.

**Методи дослідження.** Застосовано згорткові нейронні мережі, методи нормалізації та регуляризації даних, техніки аугментації зображень, експериментальне тестування на реальних наборах даних захворювань рослин.

**Наукова новизна одержаних результатів.** Удосконалено метод класифікації патологій листя рослин, який відрізняється від існуючих застосуванням комбінації нормалізації та регуляризації у п'ятиблоковій архітектурі згорткової мережі, що дозволило підвищити точність класифікації на 4% порівняно з базовою моделлю.

**Апробація результатів кваліфікаційної роботи магістра та публікації.**

Соколовський В.С., Манзюк Е.А. Метод класифікації патологій листя рослин на основі згорткових нейронних мереж. Збірник наукових праць за матеріалами XVII Всеукраїнської науково-практичної конференції «Актуальні проблеми комп'ютерних наук АПКН-2025». - Хмельницький, 2025. - С.385 – 389.

Соколовський В., Манзюк Е., Багрій Р., Скрипник Т. Підвищення точності класифікації патологій листя рослин з використанням технології створення нейронних мереж в розподілено-паралельному застосуванні з врахуванням управління ІТ проектами. (Пройшла рецензування в науковому журналі

Вимірювальна та обчислювальна техніка в технологічних процесах Хмельницького національного університету. Технічні науки).

**Структура та обсяг роботи.** Робота містить вступ, чотири розділи, висновки, список використаних джерел та додатків. Обсяг основного тексту 83 сторінки, 20 рисунків, 1 таблиця та 49 джерел у списку літератури.

**Ключові слова:** класифікація зображень, патології рослин, згорткові нейронні мережі, діагностика захворювань, машинне навчання, аугментація даних, нормалізація, dropout, автоматизація.

## Зміст

Перелік скорочень .....	4
Вступ.....	5
Розділ 1 Огляд предметної області класифікації патологій листя рослин .....	7
1.1 Характеристика задачі класифікації патологій листя рослин .....	7
1.2 Аналіз існуючих публікацій та наукових підходів.....	9
1.3 Огляд архітектур згорткових нейронних мереж для класифікації патологій листя рослин .....	11
1.4 Мета та постановка задачі.....	18
Розділ 2 Метод класифікації патологій листя рослин та критерії його оцінювання .	19
2.1 Концепція та схема методу класифікації патологій листя.....	19
2.2 Архітектура згорткової нейронної мережі .....	22
2.3 Модифікація моделі та покращення класифікації.....	27
2.4 Формування та підготовка навчальних даних .....	30
2.5 Критерії та метрики оцінювання роботи методу.....	35
Висновок до розділу 2 .....	38
Розділ 3 Програмна реалізація методу класифікації патологій листя .....	40
3.1 Вибір засобів та середовища програмної реалізації.....	40
3.2 Архітектура програмної реалізації та основні модулі .....	42
3.3 Особливості реалізації процесу навчання моделі.....	48
3.4 Особливості реалізації процесу класифікації.....	53
Висновки до розділу 3 .....	56
Розділ 4 Експериментальні дослідження та аналіз результатів .....	57
4.1 Підготовка даних та організація експериментів .....	57
4.2 Навчання базової моделі та аналіз процесу.....	60
4.3 Навчання модифікованої моделі з покращеннями .....	64
4.4 Порівняльний аналіз моделей та вплив аугментації .....	68
4.5 Аналіз помилок та складних випадків .....	71
4.6 Вплив розміру навчальної вибірки та додаткові експерименти .....	73
Висновки до розділу 4 .....	75

Загальні висновки.....	77
Перелік посилань.....	78
Додатки	

### Перелік скорочень

Скорочення, термін, позначення	Пояснення
ІІІ	Штучний інтелект
МН	Машинне навчання
CNN	Convolutional Neural Network (Згорткова нейронна мережа)
RGB	Red Green Blue (Червоний зелений синій)
ReLU	Rectified Linear Unit (Випрямлена лінійна одиниця)
IoU	Intersection over Union (Перетин об'єднання)
SGD	Stochastic Gradient Descent (Стохастичний градієнтний спуск)
Adam	Adaptive Moment Estimation (Адаптивна оцінка моменту)

## Вступ

Кваліфікаційна робота магістра присвячена розробці методу класифікації патологій листя рослин за професійними категоріями з використанням машинного навчання.

**Актуальність теми.** Актуальність напрямку обумовлена критичною необхідністю впровадження автоматизованих систем діагностики захворювань сільськогосподарських культур. Традиційні методи виявлення патологій, які базуються на візуальному огляді спеціалістами-агрономами, характеризуються високою трудомісткістю, потребують значних часових витрат та залежать від кваліфікації експерта. Системи штучного інтелекту, зокрема методи глибокого навчання, створюють можливості для суттєвого підвищення швидкості та точності діагностування захворювань рослин. Автоматизація процесів розпізнавання дозволяє виявляти патології на ранніх стадіях розвитку, коли застосування захисних заходів є найбільш ефективним. Це підкреслює актуальність роботи як для практичного застосування в аграрному секторі, так і для наукових досліджень у галузі комп'ютерного зору та автоматизованого аналізу зображень.

**Мета роботи.** Мета роботи полягає у підвищенні точності розпізнавання та класифікації патологій листя сільськогосподарських рослин шляхом розробки методу з використанням згорткових нейронних мереж та механізмів регуляризації.

Задачі дослідження

- провести аналіз існуючих методів та підходів до діагностики захворювань рослин з використанням методів машинного та глибокого навчання;
- розробити метод класифікації патологій листя з використанням згорткових нейронних мереж та механізмів регуляризації;
- спроектувати архітектуру нейронної мережі для ефективного витягнення візуальних ознак із зображень листя;
- програмно реалізувати метод розпізнавання та класифікації патологій листя сільськогосподарських рослин з використанням згорткових нейронних мереж та механізмів регуляризації;

– провести експериментальне дослідження розробленого методу шляхом порівняння різних конфігурацій архітектури та оцінки їх точності класифікації патологій рослин.

**Об'єкт дослідження** – процес автоматизованої діагностики захворювань рослин на основі аналізу зображень листя.

**Предмет дослідження** – моделі, методи та засоби класифікації патологій рослин з використанням згорткових нейронних мереж.

**Методи дослідження.** Застосовано згорткові нейронні мережі, методи нормалізації та регуляризації даних, техніки аугментації зображень, експериментальне тестування на реальних наборах даних захворювань рослин.

**Наукова новизна одержаних результатів.** Удосконалено метод класифікації патологій листя рослин, який відрізняється від існуючих застосуванням комбінації нормалізації та регуляризації у п'ятиблоковій архітектурі згорткової мережі, що дозволило підвищити точність класифікації на 4%.

**Апробація результатів кваліфікаційної роботи магістра та публікації.**

Соколовський В.С., Манзюк Е.А. Метод класифікації патологій листя рослин на основі згорткових нейронних мереж. Збірник наукових праць за матеріалами XVII Всеукраїнської науково-практичної конференції «Актуальні проблеми комп'ютерних наук АПКН-2025». - Хмельницький, 2025. - С.385 – 389.

Соколовський В., Манзюк Е., Багрій Р., Скрипник Т. Підвищення точності класифікації патологій листя рослин з використанням технології створення нейронних мереж в розподілено-паралельному застосуванні з врахуванням управління ІТ проектами. (Пройшла рецензування в науковому журналі Вимірювальна та обчислювальна техніка в технологічних процесах Хмельницького національного університету. Технічні науки).

**Структура та обсяг роботи.** Робота містить вступ, чотири розділи, висновки, список використаних джерел та додатків. Обсяг основного тексту 83 сторінки, 20 рисунків, 1 таблиця та 49 джерел у списку літератури.

## **Розділ 1 Огляд предметної області класифікації патологій листя рослин**

### **1.1 Характеристика задачі класифікації патологій листя рослин**

Задача автоматичної класифікації патологій листя рослин є важливою у сільському господарстві, оскільки захворювання рослин, спричинені грибами, бактеріями, вірусами чи шкідниками, призводять до великих втрат урожаю, погіршення якості продукції та економічних збитків [1, 2]. Ці патології можуть впливати на різні аспекти росту та розвитку рослин, включаючи фотосинтез, транспорт поживних речовин та загальну життєздатність культур. Симптоми хвороб, такі як плями, некрози, зміна кольору або деформація листя, ускладнюють діагностику через їхню схожість між різними патологіями або навіть із природними змінами, наприклад, через дефіцит поживних речовин [3, 4].

Традиційні методи діагностики, що включають візуальний огляд агрономами чи лабораторні аналізи, є трудомісткими, потребують високої кваліфікації та схильні до суб'єктивних помилок через людський фактор [5, 6]. Лабораторні методи, хоча й точні, потребують значного часу на отримання результатів, що може бути критичним у разі швидкого поширення захворювання. Автоматизовані системи на основі згорткових нейронних мереж дозволяють швидко та точно ідентифікувати патології на ранніх стадіях, що сприяє своєчасному застосуванню захисних заходів [7, 8].

Процес класифікації патологій включає кілька етапів збір даних (зображення листя різних культур, таких як томати, картопля, виноград, яблуни), попередню обробку зображень (видалення шуму, нормалізація кольорів, контрастності, сегментація уражених ділянок), витягнення ознак (аналіз текстури, кольору, форми) та власне класифікацію [9, 10]. Попередня обробка зображень є критично важливою для видалення артефактів, що можуть заважати правильній класифікації. Нормалізація кольорів компенсує різницю в освітленні між знімками, зробленими в різний час доби або при різних погодних умовах.

Складність задачі зумовлена варіативністю умов зйомки (різне освітлення, кути, фонові об'єкти), наявністю множинних патологій на одному листі, а також

обмеженою кількістю анотованих даних у деяких культурах [11, 12]. Для багатоміткової класифікації, коли лист може мати кілька хвороб одночасно, потрібні моделі, здатні передбачати кілька міток, що підвищує складність обчислень [13]. Основними метриками оцінки ефективності моделей є точність, повнота, точність передбачення, F1-міра.




Рисунок 1.1 – Хвороби сільськогосподарських культур (а) чорна плямистість; (б) ботритіс; (с) плямистість листя; (д) борошниста роса; (е) спори іржі [7]

У дослідженнях використано ЗНМ з довготривалою пам'яттю для класифікації класів патологій на датасеті PlantVillage, досягнувши високої точності. Обмеження включають чутливість до шуму в даних та складність узагальнення на зображення з різними фонами чи умовами освітлення. Також запропоновано регіональні ЗНМ для виявлення патологій томатів, але з проблемами через обмежені обчислювальні ресурси для мобільних пристроїв.

Інший виклик, це створення моделей, придатних для реального часу, наприклад, у мобільних додатках для фермерів. ЗНМ з чотирма згортковими шарами досягла високої точності на датасеті томатів, але результати погіршувалися через вплив зовнішніх факторів, таких як туман чи яскраве сонце [6]. Використано Grad-CAM для візуалізації активацій ЗНМ, що допомогло виявити помилки класифікації через фокус на фоні замість листя.

Важливим аспектом є вибір датасетів для навчання моделей. Найпоширенішим є PlantVillage, який містить велику кількість зображень різних культур та патологій [7, 8]. Однак цей датасет має обмеження через контрольовані умови зйомки з однорідним фоном. Тому дослідники часто доповнюють його власними зібраними даними або використовують інші датасети, такі як PlantLeaves та PlantDoc.

## **1.2 Аналіз існуючих публікацій та наукових підходів**

Сучасні дослідження зосереджені на використанні глибокого навчання, зокрема ЗНМ, для автоматичної класифікації патологій листя. Основна увага приділяється витягненню ознак та адаптації моделей до різних культур і умов [2, 14]. Проведено огляд ЗНМ з байєсівським навчанням, які досягли високої точності на датасеті PlantVillage [7, 8]. Однак перетренування залишається проблемою через обмежену різноманітність даних. Обмежена різноманітність даних означає, що навчальний датасет не покриває всього розмаїття можливих варіацій, які можуть зустрітися в реальних умовах.

Гібридна модель, що поєднує VGG16, Inception-V3 та DenseNet201, досягла високої точності на яблуках, але з викликами через схожість симптомів між хворобами. Використано багатозадачне навчання з EfficientNet-V3, що досягло певної точності на мульти-датасетах, застосовуючи гаусівський шум для аугментації даних [9, 10]. Багатозадачне навчання дозволяє моделі одночасно вчитися кільком пов'язаним задачам, що може покращити узагальнення.

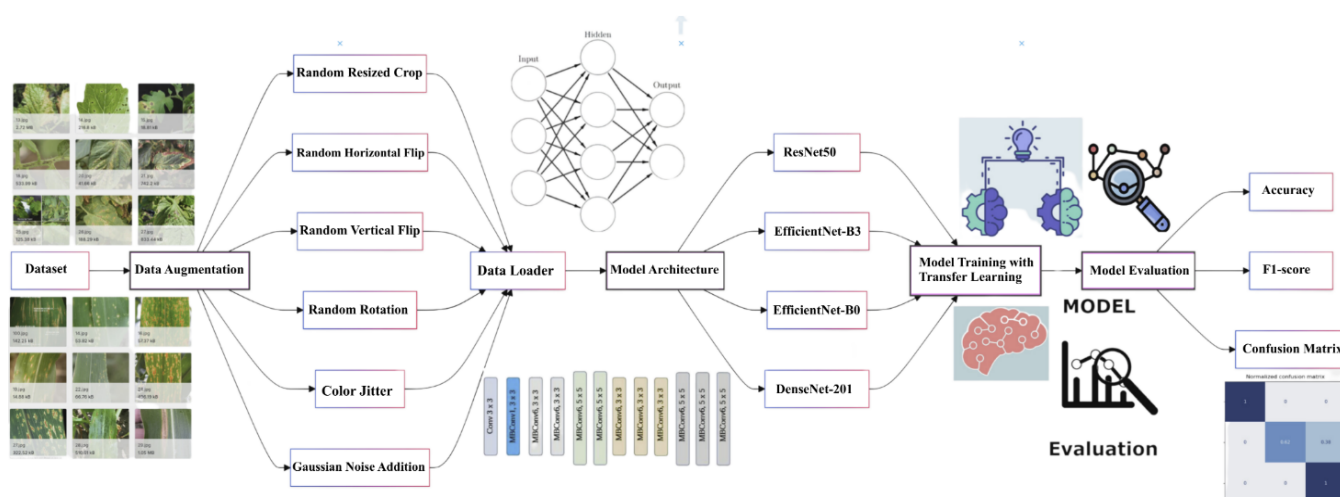


Рисунок 1.2 – Архітектура системи виявлення хвороб рослин, що ілюструє модульну конструкцію з чотирма ключовими компонентами модулі попередньої обробки даних, архітектури моделі, навчання та оцінки [10]

Трансферне навчання з Inception-V3 забезпечило високу точність на датасеті, але модель виявилася ресурсоємною. Увага-згорткові мережі досягли високої точності на PlantVillage, але з проблемами через шум у даних [12, 15, 16]. Механізми уваги дозволяють моделі динамічно фокусуватися на найбільш інформативних ділянках зображення.

Дослідження пропонують гібрид Inception-Xception, який досяг максимальної точності на PlantVillage, але розмір моделі ускладнює її використання на мобільних пристроях. Огляд трансформерів у поєднанні з ЗНМ показав високу точність з Vision Transformer, але потребує великих обчислювальних ресурсів [8, 17]. Vision Transformers представляють новий підхід до обробки зображень, запозичуючи архітектуру самоуваги з природної обробки мови.

На платформах GitHub та Kaggle доступні численні реалізації [18, 19]. ЗНМ на PlantVillage досягає високої точності, але з обмеженнями через слабе узагальнення на нових даних. EfficientNet-B4 досяг певної F1-міри, але потребує великих датасетів для стабільної роботи. Обмеженнями таких проєктів є чутливість до якості анотацій та необхідність попередньої обробки для реальних умов.

Інші роботи досліджують гібридні підходи, комбінуючи ЗНМ з LSTM для аналізу послідовностей ознак [3, 4, 20]. Комбінація згорткових та рекурентних шарів

дозволяє ефективно обробляти як просторову, так і темпоральну інформацію. Регіональні ЗНМ для томатів досягли певної точності, але з проблемами в обчислювальній ефективності. Розроблена ЗНМ з чотирма шарами досягла високої точності на помідорах, але шум у даних погіршував результати [21].

Важливим напрямком є розробка простих архітектур для мобільних пристроїв. MobileNet та його модифікації демонструють хороше співвідношення між точністю та їх швидкістю роботи [11]. Аугментація даних відіграє важливу роль у покращенні здатності узагальнення моделей. Застосовуються різні техніки обертання, масштабування, зміна яскравості та контрастності, додавання шуму. Перспективним напрямком є використання методів пояснюваного штучного інтелекту, таких як Grad-CAM, які дозволяють візуалізувати, на які ділянки зображення модель звертає увагу при класифікації [9, 10, 22].

### **1.3 Огляд архітектур згорткових нейронних мереж для класифікації патологій листя рослин**

Згорткові мережі є основою для класифікації патологій листя завдяки здатності автоматично витягувати ієрархічні ознаки з зображень. Ієрархічна природа згорткових мереж дозволяє їм вивчати ознаки різних рівнів складності від простих країв та текстур у ранніх шарах до складних семантичних концепцій у глибших шарах. Це робить їх особливо ефективними для задач розпізнавання образів, де важливі як локальні деталі, так і глобальний контекст зображення. Найпоширеніші архітектури включають VGG, ResNet, Inception, EfficientNet та їх гібриди [2, 14]. Кожна з цих архітектур має свої власні особливості та плюси, які роблять їх працездатними для різних аспектів задачі класифікації патологій рослин.

Гібрид ЗНМ з LSTM досяг високої точності на PlantVillage. Архітектура поєднує просторове витягнення ознак через згорткові шари з темпоральним моделюванням через рекурентні шари. LSTM-клітини здатні запам'ятовувати довготривалі залежності, що корисно для аналізу еволюції симптомів захворювання.

Така архітектура може обробляти не лише окремі зображення, але й послідовності спостережень, виявляючи шаблони у розвитку патології (рисунок 1.3).

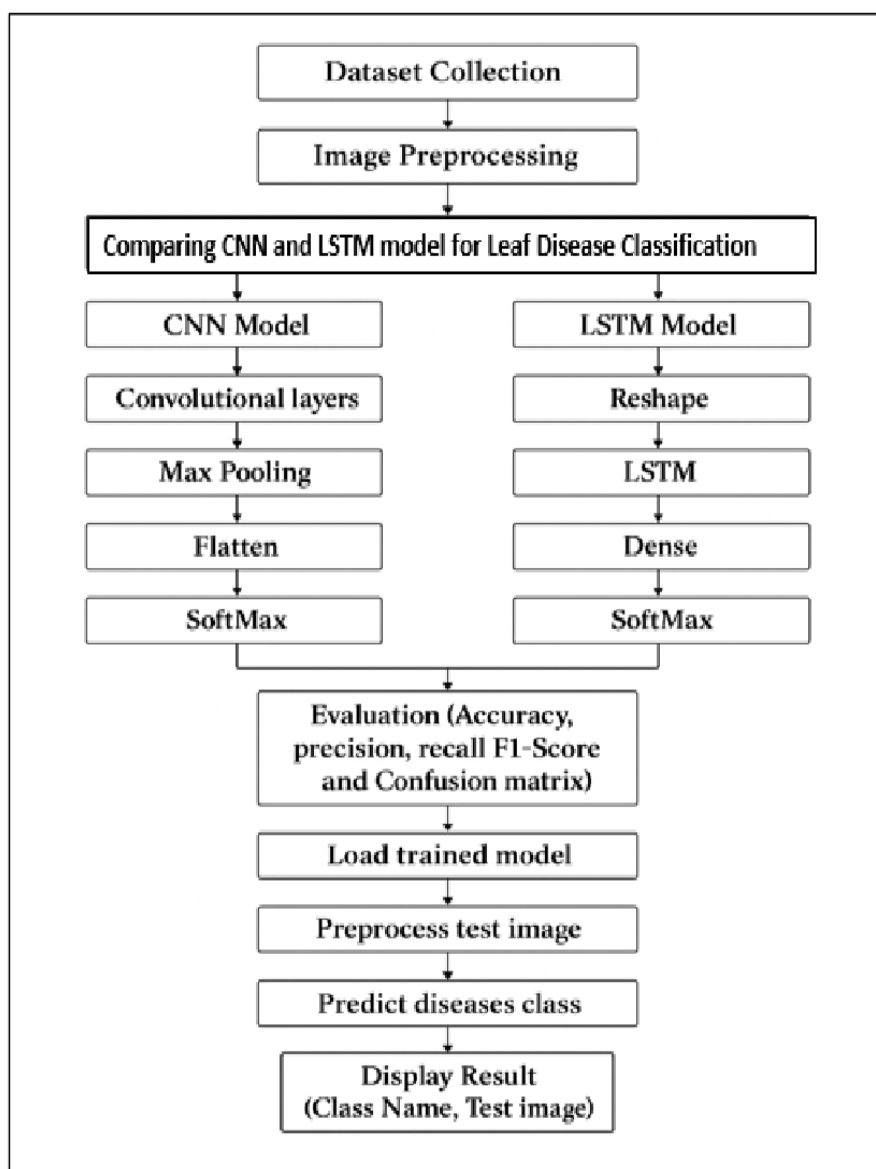


Рисунок 1.3 – Архітектура моделі для класифікації хвороб багатьох листків [3]

Регіональні ЗНМ для томатів досягли певної точності, але потребують оптимізації для мобільних пристроїв [20]. Регіональні мережі вирішують задачу одночасної детекції та класифікації об'єктів, що є більш складною проблемою порівняно з класифікацією цілого зображення. Архітектури, такі як Faster R-CNN, використовують Region Proposal Network для генерації кандидатів на регіони інтересу, які потім класифікуються та уточнюються.

ЗНМ з чотирма згортковими шарами, максимальним пулінгом, дропаутом та оптимізацією Адам досягла високої точності на датасеті томатів [21]. Архітектура дозволяє точно налаштувати складність моделі під конкретну задачу та доступні обчислювальні ресурси.

Згорткові мережі досягли високої точності на PlantVillage, використовуючи механізми уваги для фокусу на уражених ділянках [15, 16]. Механізми уваги можуть бути різним чином інтегровані на певних рівнях архітектури. Гібрид ЗНМ з трансформерами досяг високої точності, але потребує значних обчислювальних ресурсів [8]. Гібридні архітектури, що комбінують згорткові шари для витягнення локальних ознак з трансформерними блоками для моделювання глобальних залежностей, представляють перспективний напрям розвитку. Згорткові шари ефективно обробляють ранні рівні ознак, використовуючи індуктивні зміщення про локальність та трансляційну інваріантність. Трансформерні блоки на вищих рівнях моделюють складні взаємозв'язки між різними частинами зображення через самоувагу. Це дозволяє моделі розуміти глобальний контекст та виявляти просторові патерни, які можуть бути важливими для діагностики певних патологій. Високі обчислювальні вимоги трансформерів пов'язані з квадратичною складністю механізму самоуваги відносно кількості токенів.

Inception з глобальним пулінгом досяг певної точності, але з обмеженнями через розмір моделі [16]. Архітектура Inception характеризується модулями, що виконують паралельні згорткові операції з фільтрами різних розмірів, після чого результати конкатенуються. Це дозволяє моделі одночасно витягувати ознаки на різних просторових масштабах. Глобальний пулінг на фінальних шарах замінює повнозв'язані шари, значно зменшуючи кількість параметрів та ризик перетренування. Однак загальна архітектура все одно залишається досить складною через множинні паралельні шляхи обробки у кожному inception-модулі. Багатомасштабна обробка є особливо корисною для патологій, що проявляються у різних розмірах та формах уражень.

Мережі на основі щільності досягли високої точності, але потребують великих датасетів. Щільні мережі встановлюють з'єднання між всіма шарами, де

кожен шар отримує вхід від усіх попередніх шарів. Це забезпечує максимальне повторне використання ознак та покращує потік градієнтів під час навчання. Застосування різних механізмів уваги до щільної архітектури ще більше покращує здатність моделі фокусуватися на потрібних ознаках. Проте велика кількість з'єднань означає, що потрібно більше даних для ефективного навчання всіх параметрів без перетренування. Щільні з'єднання також збільшують використання пам'яті під час необхідного навчання, тому потрібно зберігати активації всіх попередніх шарів для обчислення градієнтів.

ЗНМ з байєсівським навчанням та гібрид Inception-Xception досягли високої точності відповідно [7, 17]. Байєсівське навчання дозволяє моделювати невизначеність передбачень через розподіли над параметрами моделі замість точкових оцінок. Це особливо цінно для критичних застосувань, де потрібно знати рівень впевненості системи у своїх рішеннях. Інференс у байєсівських мережах може бути виконаний через техніки, такі як викиди з механізмом Монте-Карло або варіаційний інференс. Гібрид Inception-Xception комбінує ефективність поглиблених роздільних згорток з багатомасштабною обробкою Inception-модулів, досягаючи високої точності при прийнятній складності. Xception використовує поглиблені роздільні згортки, які розділяють стандартну згортку на просторову та каналну компоненти, значно зменшуючи кількість параметрів. ЗНМ з LSTM досягли певної точності на датасеті, але з проблемами в обробці мульти-лейбл даних [23]. Мульти-лейбл класифікація вимагає модифікації функції втрат та вихідного шару моделі. Замість однієї софтмакс-активації використовуються незалежні сигмоїдні активації для кожного класу. Бінарна крос ентропійна втрата застосовується окремо для кожного класу. Це дозволяє моделі передбачати наявність або відсутність кожної патології незалежно. Проблема полягає у тому, що різні патології можуть співіснувати з різною частотою, створюючи дисбаланс не лише між класами, але й між їхніми комбінаціями. LSTM-компоненти можуть допомогти моделювати залежності між патологіями, якщо певні комбінації хвороб частіше зустрічаються разом. ResNet використовує залишкові з'єднання, які дозволяють особливостям прямо проходити через мережу, вирішуючи проблему градієнтного затухання ознак

у глибоких мережах. ResNet є відносно неглибоким варіантом, що робить його швидким та ефективним для навчання [24, 25]. Однак менша глибина може обмежувати здатність моделі до витягнення дуже складних ієрархічних ознак. Обмеження в узагальненні можуть бути пов'язані з недостатньою ємністю моделі для захоплення всього розмаїття можливих варіацій у реальних даних. Залишкові з'єднання дозволяють інформації обминати шари, що особливо корисно для навчання дуже глибоких мереж, але для задач середньої складності менш глибоких варіантів може бути достатньо. EfficientNet-B4 досяг певної F1-міри, але потребує аугментації даних. B4 є одним з масштабованих варіантів EfficientNet з більшою ємністю порівняно з базовою версією. Збільшення всіх розмірів мережі згідно з коефіцієнтами масштабування забезпечує кращу продуктивність, але також підвищує вимоги до даних. Без достатньої аугментації модель може перетренуватися на специфічних особливостях навчального датасету [26]. Ефективна аугментація збільшує різноманітність навчальних прикладів, імітуючи реальні варіації в умовах зйомки та появи симптомів. EfficientNet використовує складне комбінування – систематичне масштабування глибини, ширини та роздільної здатності мережі, що забезпечує оптимальний баланс між різними аспектами архітектури.

Дослідження пропонують ЗНМ для діагностики патологій картоплі та яблунь [27–29]. Локальні дослідження важливі для адаптації глобальних підходів до специфічних умов регіону [30, 31]. Приклади реалізацій доступні на платформах GitHub та Hugging Face [32–34]. Відкриті репозиторії не лише надають код, але й документацію, попередньо навчені ваги та інструкції для відтворення результатів. Це прискорює розвиток галузі, дозволяючи дослідникам будувати на основі існуючих рішень замість розробки з нуля. Спільнота розробників може вносити покращення, виправляти помилки та адаптувати рішення під нові задачі. ЗНМ на PlantVillage досягає високої точності. PyTorch-реалізація ЗНМ досягає високої точності, а гібридна модель з двома шляхами обробки досягає високої точності. Двошляхова обробка передбачає паралельну обробку зображення через два різні набори шарів з різними характеристиками, після чого результати об'єднуються.

Архітектура VGG характеризується простотою та використанням невеликих згорткових фільтрів. Вона добре працює на датасетах середнього розміру, залишаючись при цьому компактною [35]. ResNet вирішує проблему градієнтного затухання за допомогою залишкових з'єднань, що дозволяє навчати дуже глибокі мережі. Залишкові з'єднання створюють прямі шляхи для проходження градієнтів через мережу, дозволяючи інформації обминати один або кілька необхідних шарів. Insertion використовує модулі з паралельними згортковими операціями різних розмірів, що дозволяє ефективно витягувати ознаки на різних масштабах [36–38]. Кожен Insertion-модуль містить  $1 \times 1$ ,  $3 \times 3$  та  $5 \times 5$  згортки, а також max pooling, результати яких конкатенуються по каналах.  $1 \times 1$  згортки також використовуються для зменшення розмірності перед більшими фільтрами, що значно зменшує обчислювальні витрати. EfficientNet оптимізує співвідношення між глибиною шарів, їх шириною в мережі, досягаючи кращих результатів при менших обчислювальних витратах [39–41]. Замість довільного вибору параметрів архітектури, EfficientNet використовує одночасне масштабування всіх трьох вимірів згідно з певними коефіцієнтами. Це забезпечує збалансований розвиток архітектури, де кожен аспект доповнює інші. Базова архітектура EfficientNet-B0 була знайдена через neural architecture search, а інші варіанти отримані масштабуванням. Модель використовує мобільні інвертовані звужені блоки з оптимізацією стиснення, що забезпечує високу ефективність.

DenseNet використовує щільні з'єднання між шарами, що покращує потік градієнтів та зменшує кількість параметрів [42, 43]. У DenseNet кожен необхідний шар отримує на свій вхід дані від усіх шарів попереду через конкатенацію, а його вихід передається всім наступним шарам. Це створює пряме з'єднання між будь-якими двома шарами в одному щільному блоці. Така архітектура забезпечує максимальне повторне використання ознак, де кожен шар має доступ до ознак усіх попередніх рівнів. Це зменшує необхідність у великій кількості фільтрів на кожному шарі. Transition layers між блоками використовують  $1 \times 1$  згортки та пулінгу для контролю розмірності моделі.

Гібридні підходи, що комбінують переваги різних архітектур, часто демонструють кращі результати порівняно з окремими моделями [44–46]. Ансамблі моделей можуть агрегувати передбачення кількох різних архітектур, компенсуючи слабкості окремих компонентів їхніми сильними сторонами. Механізми уваги дозволяють моделі фокусуватися на найбільш інформативних ділянках зображення. Просторова увага генерує карту ваг, що вказує на важливість кожної просторової локації. Канальна увага визначає, які канали ознак є найбільш релевантними для задачі. Ці механізми можуть бути вбудовані в різні точки архітектури після згорткових блоків, перед пулінг операціями або між різними стадіями мережі. Навчання механізмів уваги відбувається end-to-end разом з рештою мережі через зворотне поширення. Vision Transformers представляють новий підхід до обробки зображень, розглядаючи їх як послідовності патчів та застосовуючи механізми самоуваги [47, 48]. Зображення розбивається на сітку патчів фіксованого розміру, кожен з яких лінійно проєктується у векторне представлення. Позиційне кодування додається до токенів для збереження просторової інформації. Стек transformer encoder блоків обробляє послідовність токенів, де самоувага дозволяє кожному патчу взаємодіяти з усіма іншими патчами. Це забезпечує глобальне рецептивне поле з перших шарів.

Основні виклики включають обчислювальні витрати, перетренування, шум у даних, потребу в анотованих датасетах та адаптацію до реальних умов. Обчислювальні витрати обмежують складність моделей, що можуть бути використані, особливо для застосувань реального часу. Перетренування є постійною загрозою при роботі з обмеженими датасетами. Шум у даних може походити з багатьох джерел технічних обмежень обладнання, помилок анотацій, природної варіативності біологічних об'єктів.

Гібридні моделі, що поєднують ЗНМ з трансформерами чи байєсівським навчанням, є перспективними, але потребують оптимізації для практичного використання. Комбінування сильних сторін різних підходів може призвести до синергетичних ефектів. Методи регуляризації, такі як дропаут та батч-нормалізація,

допомагають боротися з перетренуванням. Дропаут випадково вимикає частину нейронів під час навчання, змушуючи мережу вивчати більш надійні представлення.

Трансферне навчання є ефективним підходом, особливо коли доступна обмежена кількість даних. Використання попередньо навчених моделей на великих датасетах, таких як ImageNet, дозволяє перенести знання на задачу класифікації патологій листя [49]. Моделі, навчені на ImageNet, вивчають універсальні візуальні представлення низькорівневі ознаки, такі як краї та текстури, а також більш абстрактні концепції форми та структури. Замість навчання всієї мережі з нуля можна точно налаштувати попередньо навчену модель на цільовому датасеті.

#### **1.4 Мета та постановка задачі**

Відповідно до проведеного аналізу сформульовано мету та задачі дослідження.

Мета роботи полягає у підвищенні точності розпізнавання та класифікації патологій листя сільськогосподарських рослин шляхом розробки методу з використанням згорткових нейронних мереж та механізмів регуляризації.

Задачі дослідження

- провести аналіз існуючих методів та підходів до діагностики захворювань рослин з використанням методів машинного та глибокого навчання;
- розробити метод класифікації патологій листя з використанням згорткових нейронних мереж та механізмів регуляризації;
- спроектувати архітектуру нейронної мережі для ефективного витягнення візуальних ознак із зображень листя;
- програмно реалізувати метод розпізнавання та класифікації патологій листя сільськогосподарських рослин з використанням згорткових нейронних мереж та механізмів регуляризації;
- провести експериментальне дослідження розробленого методу шляхом порівняння різних конфігурацій архітектури та оцінки їх точності класифікації патологій рослин.

## **Розділ 2 Метод класифікації патологій листя рослин та критерії його оцінювання**

### **2.1 Концепція та схема методу класифікації патологій листя**

Автоматична класифікація патологій листя рослин є актуальною задачею для сучасного сільського господарства. Традиційні методи діагностики захворювань потребують залучення спеціалістів-агрономів та значних часових витрат, що ускладнює швидке реагування на поширення хвороб у полі. Згорткові мережі дають змогу автоматизувати процес розпізнавання патологій на основі аналізу фотографій листя.

Запропонований метод базується на використанні глибокого навчання для класифікації зображень листя рослин. Основна ідея методу полягає у автоматичному витягненні ознак з вхідних зображень через ієрархію згорткових шарів з наступною класифікацією через повнозв'язні шари нейронної мережі. На відміну від традиційних підходів, які потребують ручного проектування ознак, згорткові мережі автоматично навчаються виявляти значущі візуальні патерни, характерні для різних захворювань.

Концепція методу передбачає декілька послідовних етапів обробки інформації. На першому етапі робиться попередня обробка зображення на вході, яка включає зміну розміру зображення до фіксованих розмірів та нормалізацію значень пікселів. Це необхідно для приведення всіх вхідних даних до єдиного формату, з яким може працювати нейронна мережа. Попередня обробка також може включати видалення шумів та покращення контрастності для підвищення якості вхідних даних.

Другий етап полягає у витягненні ознак з попередньо обробленого зображення. Цей процес виконується автоматично згортковими шарами нейронної мережі, які послідовно витягують ознаки різного рівня складності. Ранні шари виявляють прості візуальні патерни, такі як краї, текстури та кольорові переходи. Середні шари комбінують ці прості ознаки для виявлення більш складних структур,

таких як форми плям або характерні візерунки ураження. Глибші шари формують високорівневі представлення, які відповідають конкретним типам захворювань.

На третьому етапі ознаки, які отримали, використовуються для класифікації зображення. Повнозв'язні шари нейронної мережі аналізують витягнуті ознаки та приймають рішення про належність зображення до одного з класів патологій. Вихідний шар мережі містить нейрони, кожен з яких відповідає окремому класу захворювання або здоровому стану рослини. Модель видає не просто бінарне рішення, а розподіл ймовірностей по всіх можливих класах.

Загальна схема роботи методу може бути представлена у вигляді послідовності взаємопов'язаних блоків.

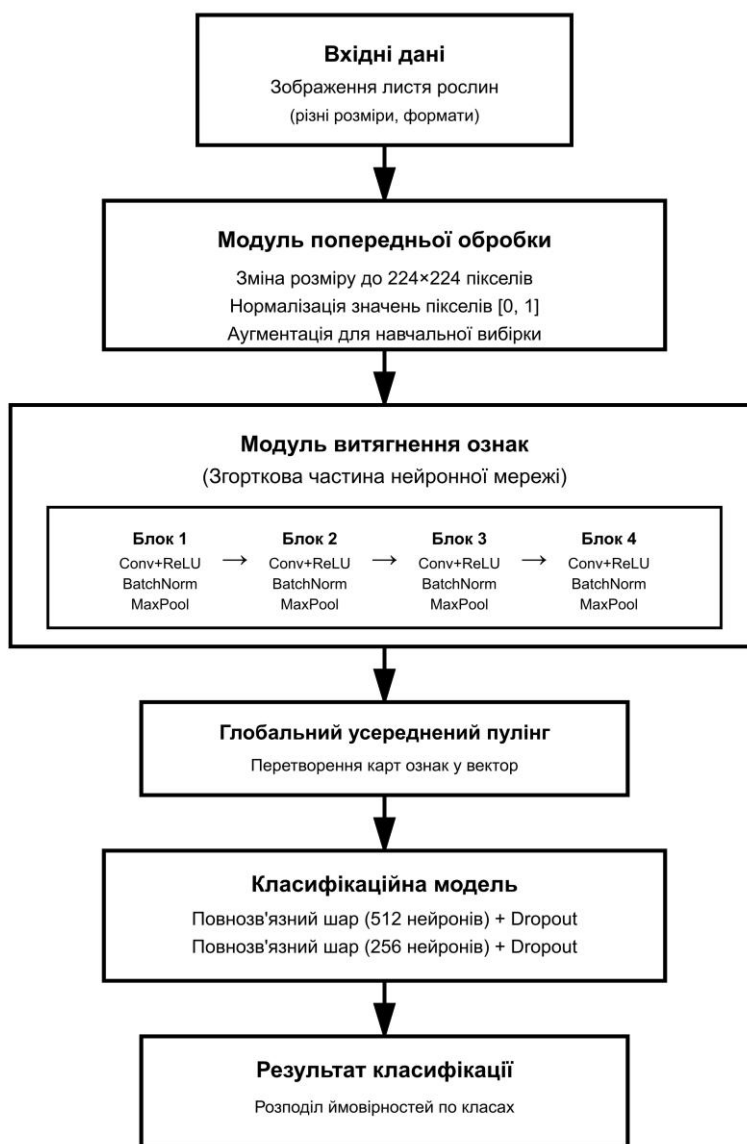


Рисунок 2.1 – Загальна схема методу класифікації патологій листя

Вхідне зображення надходить у блок попередньої обробки, де виконується нормалізація та приведення до стандартного формату. Далі оброблене зображення подається на вхід згорткової частини мережі, яка робиться з послідовності блоків. Кожен згортковий блок виконує операції згортки, активації та пулінгу для поступового витягнення та узагальнення візуальних ознак.

Після згорткової частини карти ознак перетворюються у одновимірний вектор, який подається на вхід повнозв'язної частини мережі. Повнозв'язні шари виконують фінальну обробку витягнутих ознак та формують вихідний розподіл ймовірностей. Клас з найвищою ймовірністю вибирається як результат класифікації. Така архітектура дозволяє моделі правильно оброблювати зображення різних культур та виявляти широкий спектр захворювань.

Важливою особливістю запропонованого методу є його здатність працювати з зображеннями, отриманими в різних умовах освітлення та з різних кутів зйомки. Це досягається завдяки використанню аугментації даних під час навчання моделі, що дозволяє мережі навчитися розпізнавати патології незалежно від варіативності умов зйомки. Модель стає інваріантною до певних трансформацій вхідного зображення, таких як обертання, масштабування або зміна освітлення.

Метод передбачає використання трансферного навчання для прискорення навчання та поліпшення якості результатів. Головна частина мережі може бути попередньо навчена на великому датасеті зображень загального призначення, що дозволяє їй вивчити універсальні візуальні ознаки. Потім ця попередньо навчена модель адаптується до специфічної задачі розпізнавання патологій рослин шляхом дообучення на цільовому датасеті.

Вхідними даними для методу є RGB-зображення листя рослин. Вибір кольорового представлення обумовлений тим, що багато патологій проявляються саме через зміни кольору листя, такі як пожовтіння, потемніння або появу характерних плям певного кольору. Використання лише чорно-білих зображень призвело б до втрати важливої інформації про характер ураження.

Вихідними даними методу є вектор ймовірностей належності вхідного зображення до кожного з можливих класів. Це дозволяє не тільки отримати

фінальне рішення про тип патології, але й оцінити рівень впевненості моделі у своєму рішенні. Низька впевненість може свідчити про незвичайний випадок або про необхідність додаткової експертної оцінки.

Запропонований метод орієнтований на роботу в умовах реального використання, де важлива не тільки точність розпізнавання, але й швидкість обробки зображень. Архітектура мережі підібрана таким чином, щоб забезпечити прийнятний баланс між цими характеристиками. Модель має бути достатньо компактною для розгортання на обладнанні з обмеженими обчислювальними ресурсами, але при цьому зберігати високу точність класифікації.

Метод може бути застосований для діагностики захворювань різних сільськогосподарських культур, таких як томати, картопля, виноград, яблуни та інші. Для кожної культури можуть бути характерні специфічні патології, але загальний підхід до класифікації залишається однаковим. Це робить метод універсальним інструментом для автоматизованої діагностики захворювань рослин.

Практичне застосування методу може включати інтеграцію у мобільні додатки для фермерів, системи моніторингу полів з використанням дронів або стаціонарні системи контролю у теплицях. У кожному з цих сценаріїв метод дозволяє швидко виявляти захворювання на ранніх стадіях, коли лікування є найбільш результативним. Раннє виявлення патологій допомагає зменшити використання пестицидів та мінімізувати економічні втрати.

Розроблений метод також передбачає можливість поступового покращення через донавчання на нових даних. Як тільки з'являються нові зображення захворювань або нові типи патологій, модель може бути оновлена без необхідності повного перенавчання з нуля. Це забезпечує адаптивність методу до змінюваних умов та появи нових штамів патогенів.

## **2.2 Архітектура згорткової нейронної мережі**

Архітектура згорткової мережі для класифікації патологій листя побудована на основі послідовного з'єднання шарів різних типів. Кожен тип шару виконує певну

функцію у процесі обробки зображення та витягнення ознак. Загальна структура мережі включає згорткову частину для витягнення просторових ознак та повнозв'язну частину для фінальної класифікації. В основу покладено VGG16 згорткову нейронну мережу.

Вхідний шар мережі приймає RGB-зображення розміром  $224 \times 224 \times 3$ , де перші два виміри відповідають просторовим координатам пікселів, а третій вимір відповідає трьом кольоровим каналам. Такий розмір вхідного зображення є компромісом між збереженням достатньої кількості деталей та обчислювальними витратами. Менші розміри можуть призвести до втрати важливих візуальних ознак патологій, тоді як більші розміри значно збільшують час обробки.

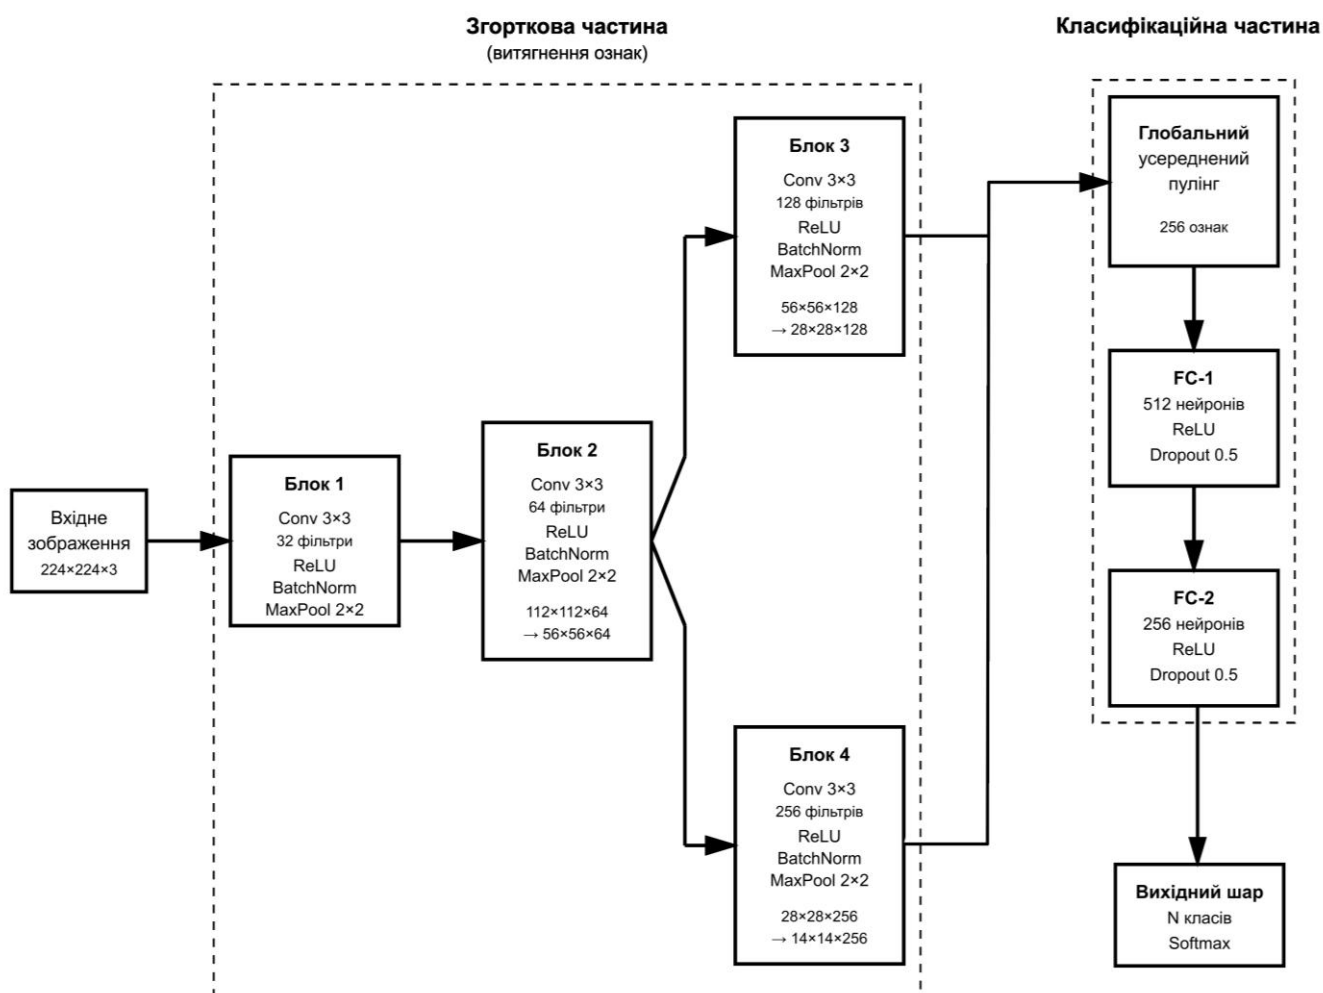


Рисунок 2.2 – Архітектура згорткової нейронної мережі

Перший згортковий блок складається з згорткового шару з 32 фільтрами розміром  $3 \times 3$  пікселі. Кожен фільтр виконує операцію згортки над вхідним зображенням, виявляючи прості візуальні патерни. Використовується параметр `stride` рівний 1, що означає переміщення фільтра на один піксель при кожному кроці. Застосовується `padding` типу `same` для збереження просторових розмірів після згортки. Це дозволяє зберігати інформацію на краях зображення, яка може бути важливою для діагностики.

Після шару згортки застосовується функція ReLU, яка додає нелінійність у модель. Функція ReLU перетворює від'ємні значення у нуль, залишаючи додатні значення без змін. Вибір саме цієї функції активації обумовлений її простотою обчислення та відсутністю проблеми затухаючих градієнтів, що часто виникає при використанні сигмоїдних функцій у глибоких мережах.

Далі розташовується шар нормалізації, який нормалізує активації попереднього шару по кожному міні-батчу. Батч-нормалізація прискорює процес навчання мережі та робить його більш стабільним, зменшуючи внутрішній зсув розподілу активацій між епохами навчання. Цей шар також має регуляризуючий ефект, що допомагає запобігти перетренуванню моделі.

Після нормалізації застосовується шар максимального пулінгу з вікном розміром  $2 \times 2$  та кроком 2. Цей шар зменшує просторову розмірність карт ознак удвічі, вибираючи максимальне значення у кожному вікні. Пулінг виконує дві важливі функції зменшує кількість параметрів моделі та вносить певний рівень інваріантності до невеликих зсувів у зображенні. Це означає, що модель може розпізнати патологію навіть якщо вона розташована трохи інакше у кадрі.

Другий згортковий блок має аналогічну структуру першому блоку, але використовує 64 фільтри розміром  $3 \times 3$ . Збільшення кількості фільтрів дозволяє мережі витягувати більше різноманітних ознак на цьому рівні абстракції. На другому рівні мережа починає виявляти більш складні комбінації простих ознак, такі як текстури або характерні візерунки, що можуть вказувати на певні типи уражень.

Структура другого блоку включає згортковий шар, активацію ReLU, батч-нормалізацію та максимальний пулінг. Така послідовність шарів стає базовим будівельним блоком архітектури та повторюється на різних рівнях глибини мережі. Консистентність структури спрощує розуміння архітектури та полегшує її модифікацію при необхідності.

Третій згортковий блок містить 128 фільтрів розміром  $3 \times 3$  та має таку саму послідовність шарів. На цьому рівні мережа комбінує ознаки з попередніх шарів для виявлення ще більш складних структур. Мережа може виявляти форми та розміри плям, характерні візерунки некрозу або інші специфічні прояви захворювань, які складно описати через прості геометричні ознаки.

Четвертий згортковий блок використовує 256 фільтрів розміром  $3 \times 3$  та завершує процес витягнення ознак з вхідного зображення. Цей блок формує високорівневі ознаки, які містять інформацію про складні візуальні патерни, специфічні для різних типів патологій. На цьому рівні представлення стають дуже абстрактними і можуть не мати прямої візуальної інтерпретації, але саме вони забезпечують можливість точної класифікації.

Після завершення згорткової частини мережі просторові карти ознак необхідно перетворити у одновимірний вектор для подальшої класифікації. Це здійснюється за допомогою шару глобального усередненого пулінгу, який обчислює середнє значення по кожній карті ознак. На відміну від простого розгортання карт у вектор, глобальний усереднений пулінг значно зменшує кількість параметрів у наступних шарах та знижує ризик перетренування.

Перший повнозв'язний шар містить 512 нейронів та використовує активацію ReLU. Цей шар аналізує витягнуті високорівневі ознаки та формує внутрішнє представлення для класифікації. Повнозв'язна природа цього шару означає, що кожен нейрон з'єднаний з усіма нейронами попереднього шару, що дозволяє моделі знаходити важкі взаємозв'язки між різними ознаками.

Для запобігання перетренуванню після першого повнозв'язного шару застосовується дропаут з коефіцієнтом 0.5. Дропаут випадково вимикає половину нейронів під час навчання, що змушує мережу вивчати більш надійні ознаки, які не

залежать від конкретних нейронів. Під час тестування всі нейрони активні, але їхні виходи масштабуються для компенсації ефекту дропауту.

Другий повнозв'язний шар містить 256 нейронів з активацією ReLU та також супроводжується дропаутом з коефіцієнтом 0.5. Додавання другого повнозв'язного шару дозволяє мережі формувати більш складні рішучі границі між класами. Це потрібно у випадках, коли різні патології мають схожі візуальні ознаки і потрібен більш глибокий аналіз для їх розрізнення.

Вихідний шар містить стільки нейронів, скільки є класів у задачі класифікації. Вихідний шар використовує функцію активації softmax, яка перетворює вихідні значення у ймовірності належності до кожного класу. Сума всіх вихідних ймовірностей дорівнює одиниці, що дозволяє інтерпретувати виходи як рівні впевненості моделі у кожному можливому діагнозі.

Загальна архітектура мережі спроектована таким чином, щоб поступово зменшувати просторову розмірність карт ознак при одночасному збільшенні кількості каналів. Початкові шари працюють з великими просторовими розмірами але малою кількістю каналів, виявляючи локальні візуальні патерни. Глибші шари працюють з меншими просторовими розмірами але більшою кількістю каналів, що дозволяє їм кодувати складні семантичні концепції.

Така структура є типовою для згорткових мереж і відображає природну ієрархію візуальних ознак від простих країв та текстур до складних об'єктів та сцен. У контексті діагностики патологій рослин це означає перехід від виявлення базових кольорових змін та форм до розпізнавання специфічних симптомів конкретних захворювань.

Кількість параметрів у мережі визначається розмірами фільтрів та кількістю нейронів у повнозв'язних шарах. Більша величина параметрів дає змогу моделі вивчати складніші залежності, але також збільшує ризик перетренування та потребує більше обчислювальних ресурсів. Вибрані параметри архітектури представляють компроміс між цими факторами.

Використання нормалізації після кожного згорткового шару та дропауту після повнозв'язних шарів забезпечує регуляризацію моделі на різних рівнях. Батч-

нормалізація діє на рівні витягнення ознак, стабілізуючи розподіл активацій, тоді як дропаут діє на рівні класифікації, запобігаючи надмірній залежності від конкретних нейронів.

Архітектура мережі є модульною, що полегшує її модифікацію та розширення. Можна легко додати або видалити згорткові блоки, змінити кількість фільтрів або розмір повнозв'язних шарів. Така гнучкість дозволяє адаптувати архітектуру під конкретні вимоги задачі або доступні обчислювальні ресурси.

### **2.3 Модифікація моделі та покращення класифікації**

Базова архітектура згорткової мережі може бути покращена для підвищення якості класифікації патологій листя. Аналіз принципів роботи глибоких мереж показує, що додавання певних шарів може дати змогу моделі краще виявляти складні візуальні патерни. Однак важливо знайти баланс між глибиною мережі та ризиком перетренування.

Запропонована модифікація полягає у додаванні одного додаткового згорткового блоку після четвертого базового блоку. Цей п'ятий блок має таку саму структуру, як і попередні блоки згортковий шар, активація ReLU, батч-нормалізація та максимальний пулінг. Використовується 256 фільтрів розміром  $3 \times 3$ , що відповідає кількості фільтрів у четвертому блоці.

Вибір саме такої модифікації обумовлений кількома міркуваннями. По-перше, додавання одного блоку є відносно простою зміною, яка не ускладнює архітектуру надмірно. По-друге, розташування додаткового блоку після базових блоків дозволяє моделі формувати ще більш абстрактні представлення вхідних зображень, використовуючи вже витягнуті ознаки з попередніх шарів.

Додатковий блок збільшує глибину згорткової частини мережі з чотирьох до п'яти блоків. Це дозволяє мережі виконати додатковий етап обробки та узагальнення ознак перед передачею їх у повнозв'язну частину. Очікується, що цей додатковий етап допоможе краще виявляти дрібні деталі патологій, які можуть бути важливими для точної класифікації.

Структура модифікованої архітектури залишається логічною та послідовною. Після п'ятого згорткового блоку карти ознак мають меншу просторову розмірність порівняно з базовою архітектурою, але зберігають ту саму кількість каналів. Глобальний усереднений пулінг, який йде після згорткових блоків, автоматично адаптується до зміненої розмірності карт ознак.

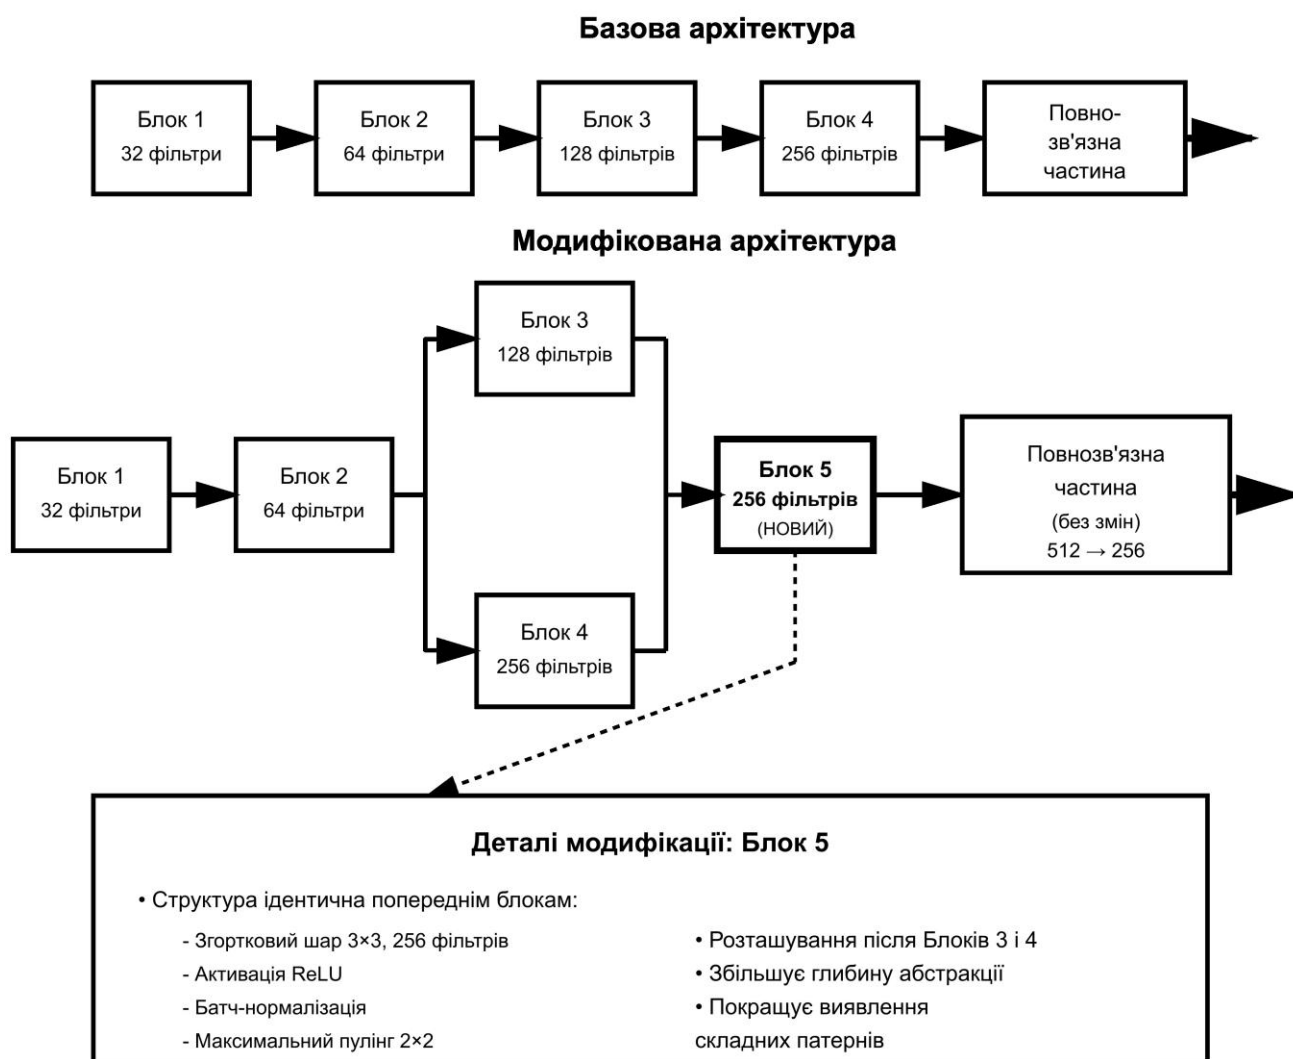


Рисунок 2.3 – Модифікована архітектура з додатковим блоком

Важливо відзначити, що модифікація не торкається повнозв'язної частини мережі. Структура повнозв'язних шарів залишається такою самою два приховані шари з 512 та 256 нейронами відповідно, з дропаутом між ними. Це рішення

базується на припущенні, що основне покращення має прийти від розширення можливостей витягнення ознак, а не від змін у класифікаційній частині.

Додавання п'ятого блоку збільшує загальну кількість параметрів моделі. Це означає, що модифікована модель потребуватиме трохи більше часу для навчання та інференсу порівняно з базовою версією. Однак це збільшення є помірним і не створює значних обчислювальних проблем для сучасного обладнання.

Модифікована архітектура зберігає всі механізми регуляризації, що використовувалися у базовій версії. Батч-нормалізація застосовується після кожного згорткового шару, включаючи новий п'ятий блок. Дропаут використовується після повнозв'язних шарів. Це дозволяє зберегти стійкість до перетренування навіть при збільшенні кількості параметрів.

Процес навчання модифікованої моделі не потребує значних змін порівняно з базовою версією. Використовуються ті самі гіперпараметри навчання швидкість навчання, розмір батчу, кількість епох. Це дозволяє коректно порівняти результати базової та модифікованої версій, оскільки єдина відмінність полягає в архітектурі, а не в процесі навчання.

Очікується, що модифікація призведе до покращення якості класифікації завдяки можливості моделі виявляти більш тонкі відмінності між різними патологіями. Додатковий рівень абстракції може бути особливо корисним для розрізнення захворювань, які мають схожі візуальні прояви на ранніх стадіях розвитку.

Альтернативні підходи до модифікації архітектури, такі як збільшення кількості фільтрів у існуючих блоках або додавання більше повнозв'язних шарів, були розглянуті але відхилені. Збільшення кількості фільтрів призводить до значного зростання кількості параметрів без гарантії покращення результатів. Додавання повнозв'язних шарів не вирішує завдання покращення витягнення візуальних ознак.

Модифікована архітектура залишається достатньо компактною для практичного використання. Вона може бути розгорнута на звичайних персональних комп'ютерах або навіть на мобільних пристроях при необхідності. Це важливо для

реального застосування системи діагностики у польових умовах, де доступ до потужних обчислювальних ресурсів може бути обмеженим.

Запропонована модифікація є поступовим покращенням архітектури на основі розуміння принципів роботи згорткових мереж. Замість радикальних змін використовується обережний підхід з додаванням однієї додаткової компоненти. Це дозволяє краще контролювати вплив модифікації на результати та спрощує процес налагодження моделі.

## **2.4 Формування та підготовка навчальних даних**

Для навчання згорткової мережі потрібно репрезентативний датасет зображень листя рослин у різних станах. Якість та величина навчальних даних великою мірою впливають на здатність моделі узагальнювати знання на нові, раніше не бачені зображення. Процес формування та підготовки даних включає кілька важливих етапів. Вихідні зображення у датасеті мають різну роздільну здатність та співвідношення сторін, оскільки вони отримані з різних джерел та за допомогою різного обладнання. Це відображає реальні умови, в яких буде використовуватися система користувачі можуть робити фотографії за допомогою різних систем або камер. Така варіативність робить задачу класифікації більш складною, але й більш практично орієнтованою.

Перший етап підготовки даних полягає у зміні розміру всіх зображень до фіксованих розмірів  $224 \times 224$  пікселі. Цей розмір обраний виходячи з декількох міркувань. Він є достатньо великим для збереження важливих візуальних деталей патологій, таких як форма плям або характер уражених ділянок. Водночас він не є надмірно великим, що дозволяє ефективно обробляти зображення навіть на обладнанні з обмеженими обчислювальними ресурсами.

Зміна розміру виконується з використанням білінійної інтерполяції, яка забезпечує гладке масштабування зображення. При зміні розміру зберігається оригінальне співвідношення сторін зображення шляхом додавання відступів або

обрізання країв. Це важливо для уникнення спотворень, які могли б вплинути на візуальні характеристики патологій.

Другий етап попередньої обробки включає нормалізацію значень пікселів. Оригінальні значення пікселів знаходяться в діапазоні від 0 до 255 для кожного кольорового каналу. Ці значення нормалізуються діленням на 255, що приводить їх до діапазону від 0 до 1. Нормалізація є стандартною практикою при роботі з нейронними мережами, оскільки вона полегшує процес навчання та прискорює збіжність.

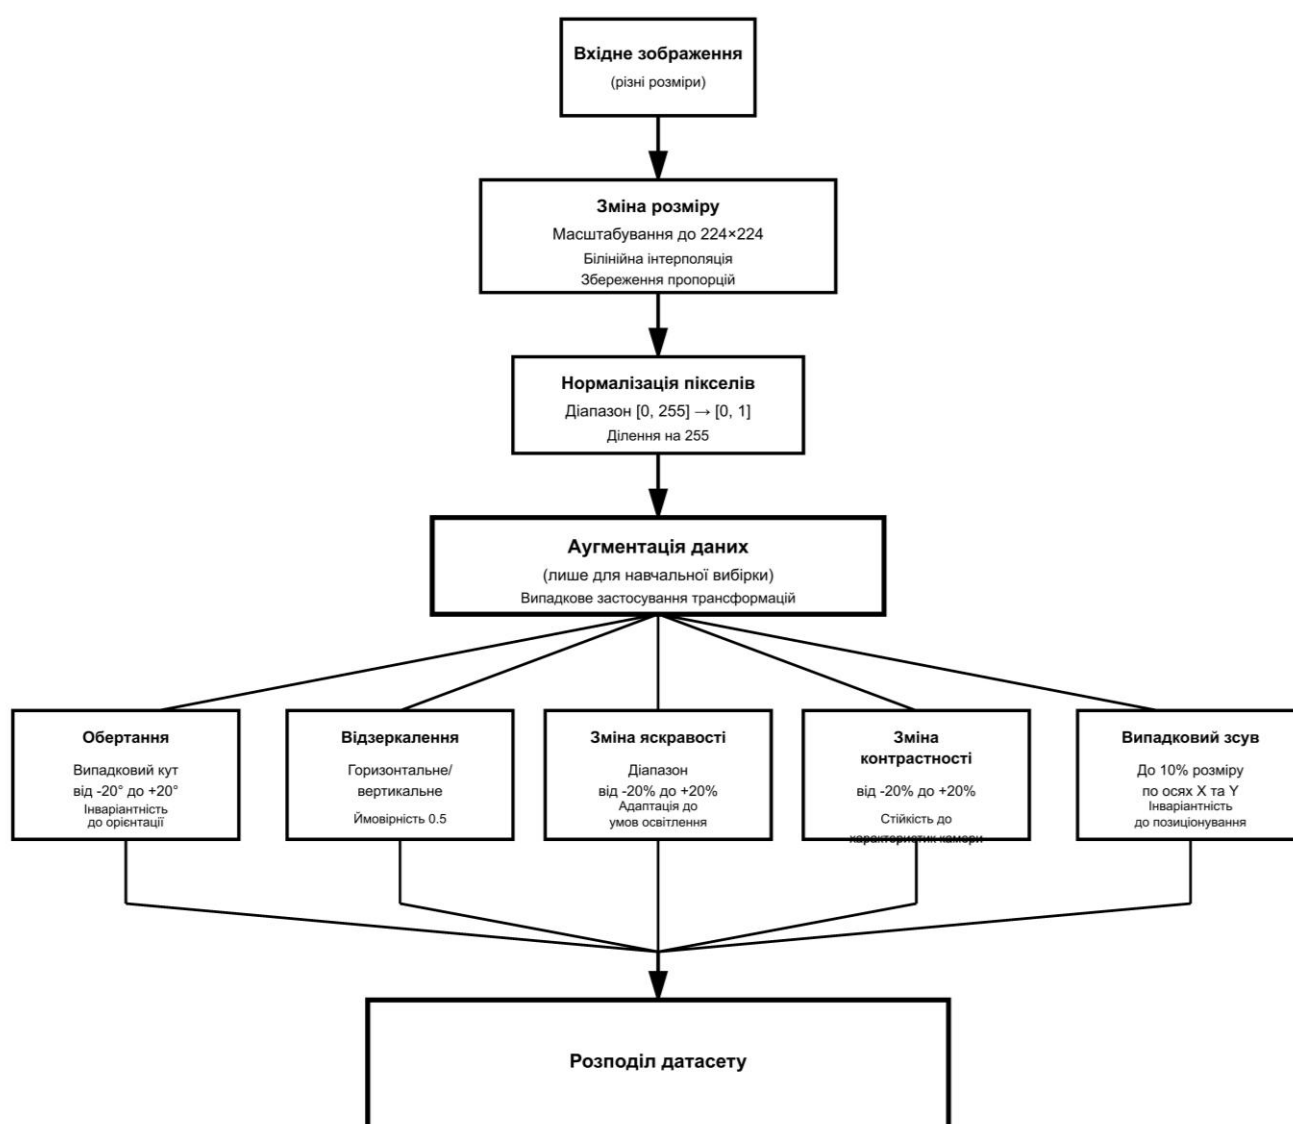


Рисунок 2.4 – Схема попередньої обробки зображень

Аугментація даних є критично важливою технікою для підвищення якості навчання моделі. Аугментація дозволяє збільшити кількість навчальної вибірки без необхідності збору нових фотографій. Більш важливо те, що аугментація робить модель інваріантною до певних трансформацій вхідних даних, які не змінюють семантичний зміст зображення.

Випадкове обертання зображень на кут до 20 градусів у будь-якому напрямку є першою технікою аугментації. Листя може бути сфотографоване під різними кутами в реальних умовах, тому модель повинна вміти розпізнавати патології незалежно від орієнтації листка. Обмеження кута обертання 20 градусами забезпечує, що зображення залишається природним і не втрачає важливих візуальних характеристик.

Горизонтальне та вертикальне відзеркалення застосовується випадково з ймовірністю 0.5 для кожного напрямку. Відзеркалення є корисною технікою, оскільки патології виглядають однаково при дзеркальному відображенні. Це дозволяє подвоїти кількість унікальних прикладів у навчальній вибірці без зміни семантичного змісту зображень. Модель навчається розпізнавати захворювання незалежно від того, з якого боку сфотографовано листок.

Випадкова зміна яскравості файлу зображення в діапазоні від -20% до +20% від оригінального значення допомагає моделі адаптуватися до різних умов освітлення. У реальних умовах фотографії можуть бути зроблені при яскравому сонячному світлі, у похмуру погоду або навіть у приміщенні. Модель повинна вміти розпізнавати патології незалежно від загальної яскравості зображення.

Зміна контрастності у діапазоні від -20% до +20% є ще однією важливою технікою аугментації. Контраст між здоровою тканиною листка та ураженими ділянками може варіюватися залежно від характеристик камери та умов зйомки. Аугментація контрастності робить модель стійкою до таких варіацій, дозволяючи їй фокусуватися на структурних особливостях патологій, а не на відносних значеннях контрасту.

Випадковий зсув зображення по горизонталі та вертикалі на відстань до 10% від розміру зображення робить модель інваріантною до точного розташування

листка у кадрі. У практичному використанні користувачі не завжди центрують листок ідеально при фотографуванні. Зсув під час аугментації навчає модель виявляти патології незалежно від того, де саме у кадрі розташоване листя.

Всі техніки аугментації застосовуються випадково та можуть комбінуватися між собою. Це означає, що одне й те саме оригінальне зображення може породжувати велику кількість різних варіантів під час процесу навчання. Кожна епоха навчання бачить дещо інші версії тих самих зображень, що значно збагачує навчальну вибірку та покращує здатність моделі до узагальнення.

Аугментація виконується в режимі реального часу під час процесу навчання, а не перед ним. Це означає, що модифіковані версії зображень генеруються безпосередньо перед подачею батчу в мережу. Такий підхід має перевагу в тому, що не потрібно зберігати велику кількість аугментованих зображень на диску. Кожного разу генеруються нові випадкові варіанти, що забезпечує максимальну різноманітність.

Датасет розділяється на три незалежні вибірки для коректної оцінки якості моделі. Навчальна вибірка містить 70% від загальної кількості зображень і використовується безпосередньо для моделі. На даних мережа оновлює свої ваги через алгоритм зворотного поширення помилки. Навчальна вибірка є найбільшою, оскільки саме вона визначає, які патерни вивчить модель.

Валідаційна вибірка становить 15% датасету і використовується для моніторингу якості моделі під час процесу навчання. Після кожної епохи навчання модель оцінюється на валідаційній вибірці, що дозволяє відстежувати, чи не відбувається перетренування. Якщо точність на валідаційній вибірці перестає зростати або починає знижуватися при зростанні точності на навчальній вибірці, це є сигналом перетренування.

Валідаційні дані не беруть участі в оновленні ваг мережі. Вони використовуються виключно для оцінки та прийняття рішень щодо процесу навчання. На основі результатів на валідаційній вибірці можна визначити оптимальний момент для зупинки навчання або необхідність зміни гіперпараметрів, таких як швидкість навчання.

Тестова вибірка також становить 15% датасету і зберігається повністю ізольованою протягом всього процесу розробки та навчання моделі. Вона використовується лише на фінальному етапі для об'єктивної оцінки якості натренованої моделі. Результати на тестовій вибірці показують, наскільки добре модель працюватиме на нових, повністю незнайомих даних у реальних умовах.

Розподіл датасету виконується із забезпеченням збалансованого представлення всіх класів у кожній вибірці. Це означає, що пропорції різних типів патологій приблизно однакові в навчальній, валідаційній та тестовій вибірках. Такий підхід запобігає ситуації, коли модель добре навчається розпізнавати одні класи, але погано працює з іншими через дисбаланс даних.

Важливо забезпечити, щоб зображення одного й того самого листка не потрапили одночасно в різні вибірки. Якщо є кілька фотографій одного листка, зроблених з різних кутів, всі вони повинні бути віднесені до однієї вибірки. Це запобігає витоку інформації між вибірками, який міг би призвести до завищеної оцінки якості моделі.

Процес попередньої підготовки даних також включає перевірку якості анотацій. Кожне зображення повинно бути правильно позначене відповідним класом патології. Помилки в анотаціях можуть значно погіршити якість навчання, оскільки модель намагатиметься вивчити некоректні зв'язки між візуальними ознаками та класами захворювань.

У випадках, коли датасет містить зображення поганої якості, такі як надмірно розмиті або сильно затемнені фотографії, може бути доцільним їх видалення з навчальної вибірки. Низькоякісні зображення можуть заважати навчанню, вносячи шум у дані. Однак якщо такі зображення відображають реальні умови використання системи, їх варто зберегти для підвищення стійкості моделі.

Статистичний аналіз датасету допомагає зрозуміти його характеристики та виявити можливі проблеми. Корисно проаналізувати розподіл класів, середні характеристики зображень кожного класу, наявність аномальних прикладів. Така інформація допомагає приймати обґрунтовані рішення щодо стратегії навчання та необхідних модифікацій архітектури.

Підготовка вхідних даних є процесом ітеративним, який може потребувати кількох циклів налаштування. Після початкового навчання моделі аналіз помилок може виявити, що певні типи зображень класифікуються погано. Це може вказувати на необхідність збільшення кількості таких прикладів у навчальній вибірці або застосування додаткових технік аугментації.

## **2.5 Критерії та метрики оцінювання роботи методу**

Для об'єктивної оцінки якості роботи методу класифікації патологій листя необхідно використовувати відповідні метрики та критерії. Вибір метрик залежить від специфіки задачі та вимог до практичного застосування системи. У випадку діагностики захворювань рослин важливими є як загальна точність розпізнавання, так і здатність правильно виявляти кожен конкретний тип патології.

Точність класифікації є найбільш базовою та інтуїтивно зрозумілою метрикою. Вона показує частку правильно класифікованих зображень від загальної кількості зображень у вибірці. Точність обчислюється як відношення кількості коректних передбачень до загальної кількості передбачень. Ця метрика дає загальне уявлення про якість роботи моделі, але може бути оманливою у випадку дисбалансу класів.

У випадку збалансованого датасету, де кількість прикладів кожного класу приблизно однакова, висока точність дійсно свідчить про добру роботу моделі. Однак якщо один клас представлений значно частіше за інші, модель може досягти високої точності, просто завжди передбачаючи цей домінуючий клас. Тому важливо використовувати додаткові метрики для повної оцінки якості.

Точність передбачення для конкретного класу показує, яка частка зображень, які модель віднесла до цього класу, дійсно належить йому. Це відношення кількості правильно ідентифікованих зображень класу до загальної кількості зображень, які модель класифікувала як цей певний клас. Висока точність передбачення означає, що коли модель каже, що листок має певне захворювання, вона рідко помиляється.

У контексті діагностики захворювань рослин висока точність передбачення є важливою, оскільки вона визначає, наскільки можна довіряти позитивному діагнозу моделі. Якщо модель часто помилково ідентифікує здорові рослини як хворі, це може призвести до непотрібного застосування засобів захисту рослин та додаткових витрат.

Повнота для конкретного класу показує, яку частину всіх зображень певного класу модель змогла правильно та коректно ідентифікувати. Це відношення кількості правильно ідентифікованих зображень класу до загальної кількості зображень цього класу в датасеті. Висока повнота означає, що модель рідко пропускає випадки певного захворювання.

Повнота є особливо важливою метрикою для небезпечних або швидко поширюваних захворювань. Пропуск такого захворювання може призвести до великих втрат урожаю, тому що не будуть вчасно застосовані захисні заходи. Для критичних патологій може бути прийнятним деяке зниження точності передбачення заради підвищення повноти виявлення.

F1-міра є гармонічним середнім між точністю передбачення та повнотою. Ця метрика враховує обидва аспекти якості класифікації та досягає високого значення лише тоді, коли обидві складові є високими. F1-міра особливо корисна для порівняння різних моделей, оскільки вона дає збалансовану оцінку їхньої якості.

Гармонічне середнє використовується замість арифметичного, оскільки воно більш чутливе до низьких значень. Це означає, що модель не має змоги досягти високої F1-міри, маючи високу точність передбачення але низьку повноту, або навпаки. Така властивість робить F1-міру особливо придатною для оцінки якості класифікаторів у практичних застосуваннях.

Для багатокласової класифікації, якою є задача діагностики патологій, можна обчислювати F1-міру для кожного класу окремо, а потім усереднювати ці значення. Існує два основні підходи до усереднення макро-усереднення та мікро-усереднення. Макро-усереднення обчислює F1-міру для кожного класу окремо і потім усереднює, надаючи кожному класу однакову вагу незалежно від його розміру.

Матриця помилок є корисним інструментом для детального аналізу роботи класифікатора. Вона показує, скільки зображень кожного класу було класифіковано як кожен з можливих класів. Діагональні елементи матриці відповідають правильним класифікаціям, тоді як недіагональні елементи показують типи помилок, які робить модель.

Аналіз матриці помилок може виявити систематичні проблеми моделі. Наприклад, якщо модель часто плутає два конкретні типи захворювань, це може вказувати на схожість їхніх візуальних проявів та необхідність збільшення кількості навчальних прикладів для цих класів або додаткової аугментації, яка б краще виділяла відмінності.

Час інференсу, тобто час, необхідний для класифікації одного зображення, є важливою практичною характеристикою методу. Для застосувань реального часу, таких як мобільні додатки для фермерів або системи моніторингу на базі дронів, швидкість обробки може бути так само важливою, як і точність розпізнавання.

Вимірювання часу інференсу повинно проводитися на цільовому обладнанні, оскільки швидкість обробки сильно залежить від апаратних характеристик. Модель може працювати дуже швидко на потужному сервері з GPU, але значно повільніше на смартфоні. Для мобільних застосувань прийнятним вважається час обробки менше однієї секунди на зображення.

Використання пам'яті є ще одним важливим практичним критерієм. Модель повинна поміщатися в доступну пам'ять цільового пристрою та залишати достатньо ресурсів для роботи інших компонентів системи. Для мобільних пристроїв це особливо критично, оскільки вони мають обмежену оперативну пам'ять.

Розмір моделі у файлі також має значення для практичного застосування. Великі моделі потребують більше часу для завантаження та можуть створювати проблеми при розповсюдженні через мобільні мережі. Бажано, щоб розмір моделі не перевищував кількох десятків мегабайт для зручного розгортання на мобільних пристроях.

Стабільність передбачень є важливим параметром для практичного використання. Модель повинна давати стабільні результати для множинних

фотографій того самого листка, зроблених з невеликою різницею у часі або кут зйомки. Велика варіативність передбачень для схожих зображень знижує довіру користувачів до системи.

Критерій успішності методу визначається на основі комбінації цих метрик. Для практичного застосування може бути встановлено мінімальні порогові значення для основних метрик. Наприклад, метод вважається прийнятним, якщо його точність перевищує 90%, F1-міра для кожного класу перевищує 0.85, а час інференсу на цільовому пристрої не перевищує однієї секунди.

Порівняння з базовими моделями є стандартною практикою для демонстрації покращень запропонованого методу. Базовою моделлю може бути попередня версія архітектури, стандартна архітектура без модифікацій або традиційні методи машинного навчання. Порівняння повинно проводитися на однакових даних та з використанням однакових метрик для забезпечення об'єктивності.

Крос-валідація може використовуватися для більш надійної оцінки якості методу, особливо якщо розмір датасету є обмеженим. Крос-валідація передбачає розділення даних на кілька частин та багаторазове навчання моделі з використанням різних комбінацій цих частин для роботи. Це дозволяє отримати більш стабільну оцінку очікуваної якості роботи методу на нових даних.

## **Висновок до розділу 2**

У другому розділі представлено розроблений метод автоматичної класифікації патологій листя рослин на основі згорткових мереж. Описано концепцію та загальну схему роботи методу, яка включає етапи попередньої обробки зображень, витягнення ознак через згорткові шари та класифікації через повнозв'язні шари.

Розглянуто архітектуру згорткової мережі, яка складається з чотирьох базових згорткових блоків та двох повнозв'язних шарів. Кожен згортковий блок включає операції згортки, активації ReLU, нормалізації та максимального пулінгу.

Така структура дозволяє мережі послідовно витягувати ієрархічні візуальні ознаки від простих до складних.

Запропоновано модифікацію базової архітектури шляхом додавання п'ятого згорткового блоку для покращення виявлення складних візуальних патернів патологій. Модифікація є помірною та не ускладнює архітектуру надмірно, зберігаючи можливість практичного застосування методу на обладнанні з обмеженими ресурсами.

Описано процес формування та підготовки навчальних даних, включаючи попередню обробку зображень, техніки аугментації та розподіл датасету на навчальну, валідаційну та тестову вибірки. Застосування аугментації даних дозволяє підвищити стійкість моделі до варіативності умов зйомки.

Обґрунтовано вибір критеріїв та метрик для оцінювання якості роботи методу, включаючи точність класифікації, точність передбачення, повноту та F1-міру. Ці метрики дозволяють всебічно оцінити якість класифікації та виявити сильні і слабкі сторони методу.

## **Розділ 3 Програмна реалізація методу класифікації патологій листя**

### **3.1 Вибір засобів та середовища програмної реалізації**

Для практичного втілення запропонованого методу класифікації патологій листя рослин необхідно було обрати відповідні інструменти розробки, які забезпечили б можливість створення та навчання згорткових мереж. Вибір засобів розробки здійснювався з урахуванням декількох важливих критеріїв. Інструменти мають підтримувати сучасні архітектури нейронних мереж та надавати зручний програмний інтерфейс для їх побудови. Необхідна наявність засобів для роботи з графічними процесорами, тому що навчання мереж потребує великих обчислювальних ресурсів. Бажано використовувати широко поширені рішення з великою спільнотою розробників та якісною документацією.

Основною мовою програмування для реалізації було обрано Python версії 3.10. Цей вибір обумовлений кількома причинами. Python є однією з найпоширеніших мов у галузі машинного навчання та аналізу даних. Мова має простий та зрозумілий синтаксис, що спрощує написання та підтримку коду. Для Python існує велика кількість спеціалізованих бібліотек, призначених для роботи з мережами та обробки зображень. Крім того, Python добре підходить для розробки базових програм та проведення експериментів, що важливо на етапі дослідження різних архітектур мереж.

Для побудови та навчання згорткової мережі було використано бібліотеку TensorFlow версії 2.13 разом з високорівневим програмним інтерфейсом Keras. TensorFlow є однією з найпопулярніших платформ для глибокого навчання, яка розроблена компанією Google. Ця бібліотека надає можливості для ефективного виконання обчислень як на центральних процесорах, так і на графічних процесорах. Keras, який інтегрований в TensorFlow, дозволяє будувати нейронні мережі у зручний спосіб, використовуючи високорівневі абстракції. Це значно спрощує процес створення моделі та зменшує кількість коду, необхідного для визначення архітектури мережі.

Для того, щоб працювати з зображеннями використовувалась бібліотека Pillow версії 10.0, яка є розвитком класичної бібліотеки Python Imaging Library. Pillow надає зручні засоби для завантаження зображень у різних форматах, зміни їх розміру, обертання та інших базових операцій обробки. Ця бібліотека добре інтегрується з TensorFlow та дозволяє легко перетворювати зображення у формат, добрий для подавання на вхід нейронної мережі.

Для обробки та аналізу зображень застосовувалась бібліотека OpenCV версії 4.8. OpenCV є потужним інструментом для комп'ютерного зору, який містить велику кількість алгоритмів обробки зображень. У даній роботі OpenCV використовувався для виконання більш складних перетворень зображень, таких як зміна яскравості та контрасту, застосування різних фільтрів та геометричних перетворень під час аугментації навчальних даних.

Для обробки числових масивів та виконання математичних операцій було залучено бібліотеку NumPy версії 1.24. NumPy є фундаментальною бібліотекою для обчислень у Python та забезпечує правильну роботу з багатовимірними масивами. Всі основні бібліотеки машинного навчання, включаючи TensorFlow, використовують NumPy для представлення даних, тому ця бібліотека є обов'язковою складовою програмного середовища.

Для візуалізації результатів навчання та побудови графіків використовувалась бібліотека Matplotlib версії 3.7. Ця бібліотека дозволяє створювати різноманітні графіки, діаграми та інші види візуалізацій. За її допомогою було побудовано графіки точності та втрат під час навчання, матриці помилок та інші візуальні матеріали для аналізу роботи моделі.

Розробка та тестування програмної реалізації проводились у середовищі PyCharm версії. PyCharm є середовищем, яке дозволяє виконувати код частинами, зберігати проміжні результати та поєднувати код з текстовими поясненнями та візуалізаціями. Це середовище дуже зручне для експериментів з машинним навчанням, оскільки дозволяє легко змінювати параметри моделі, перезапускати навчання та аналізувати результати без необхідності кожного разу запускати весь код заново.

Для контролю версій програмного коду використовувалась система Git, а для зберігання репозиторію – платформа GitHub. Це дозволило відстежувати зміни під час програмування, зберігати різні версії реалізації та забезпечити резервне копіювання роботи. Використання системи контролю версій є важливою практикою у розробці програмного забезпечення, яка допомагає уникнути втрати коду та полегшує повернення до попередніх версій у разі необхідності.

Структура програмного проекту організована таким чином, щоб забезпечити зручність розробки та підтримки коду. Всі програмні файли розділені на декілька систем, кожна відповідає за певну функціональність. Такий підхід дозволяє легко вносити зміни в окремі частини системи без впливу на інші необхідні компоненти.

Для зберігання навчених моделей використовується стандартний формат TensorFlow SavedModel, який зберігає як архітектуру мережі, так і навчені ваги. Це дозволяє легко завантажувати натреновану модель для використання далі без необхідності навчання в повторному режимі. Результати експериментів, включаючи графіки та числові метрики, зберігаються у форматі текстових файлів та зображень для подальшого аналізу.

Обране програмне середовище забезпечує всі необхідні можливості для реалізації запропонованого методу класифікації. Комбінація Python з бібліотеками TensorFlow та іншими спеціалізованими інструментами дозволяє ефективно побудувати, навчити та протестувати згорткову нейронну мережу.

### **3.2 Архітектура програмної реалізації та основні модулі**

Програмна реалізація методу класифікації патологій листя рослин побудована за модульним принципом із застосуванням об'єктно-орієнтованого підходу. Така організація коду забезпечує його структурованість, полегшує розуміння логіки роботи системи та спрощує можливість внесення змін або доповнень у майбутньому. Загальна архітектура складається з декількох модулів функціональності, які взаємодіють між собою у певній послідовності для виконання задачі класифікації.

Для представлення структури програмної системи було розроблено діаграму класів, яка показує основні програмні компоненти та їх взаємозв'язки (рисунок 3.1). На діаграмі представлено сім основних класів, кожен з яких відповідає за певний аспект роботи системи. Класи організовані таким чином, щоб забезпечити розділення відповідальностей та мінімізувати зв'язаність між компонентами.

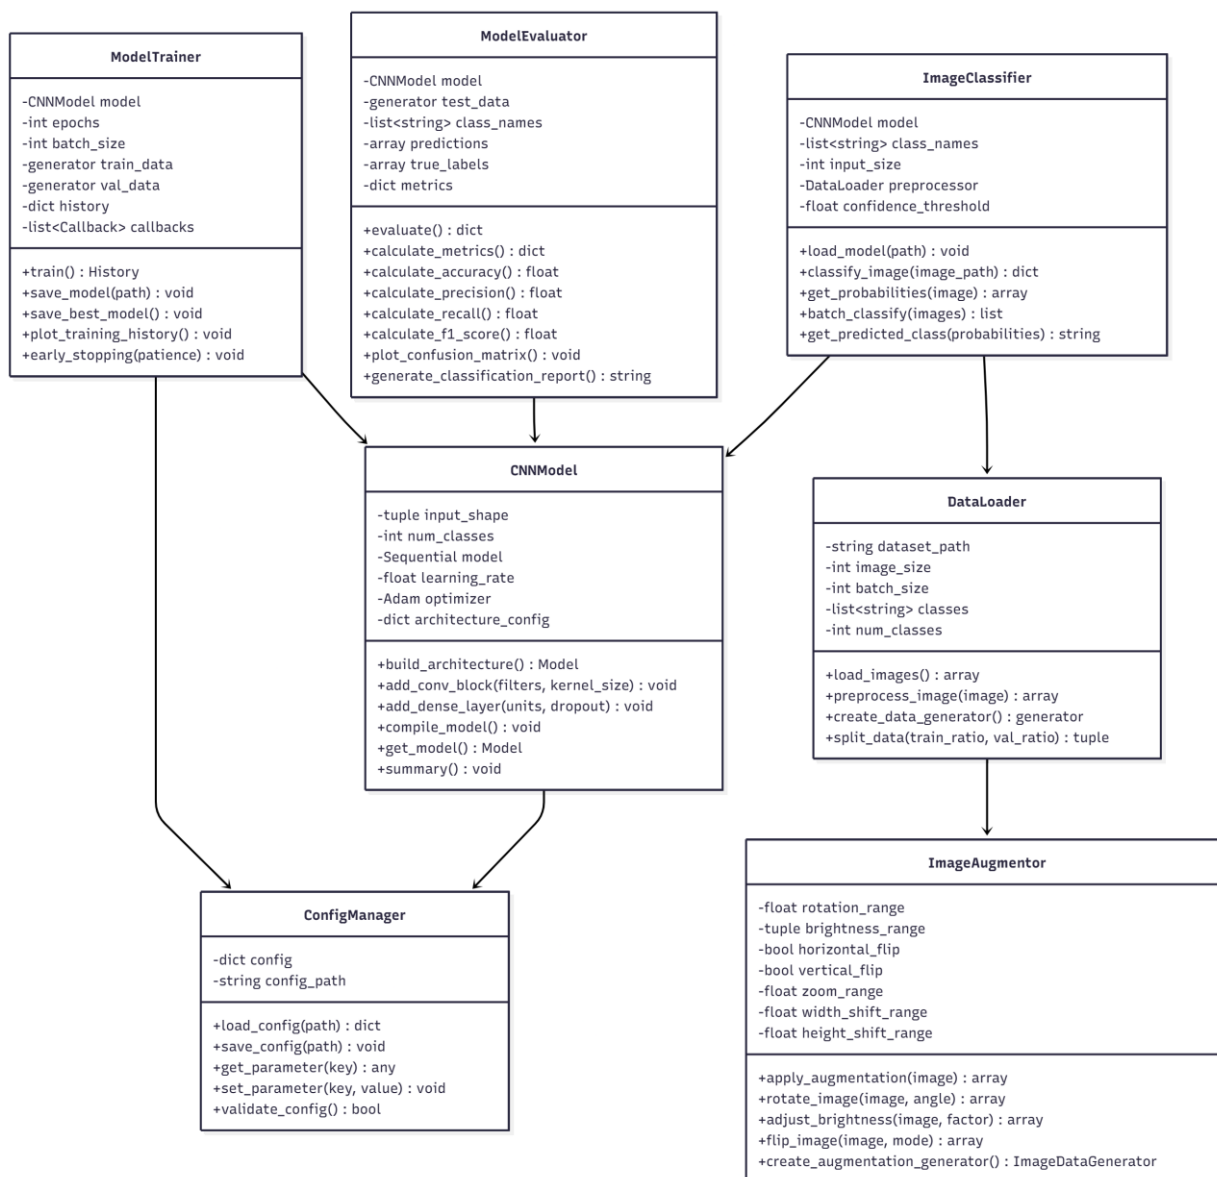


Рисунок 3.1 – Діаграма класів

Клас `DataLoader` відповідає за завантаження та попередню обробку зображень з диску. Цей клас інкапсулює всю логіку роботи з файловою системою, читання зображень, їх перевірку на коректність та базову обробку. До основних

атрибутів класу належать шлях до датасету, розмір зображень для обробки, розмір пакету даних та список класів захворювань. Клас надає методи для завантаження зображень, попередньої обробки окремого зображення та створення генератора даних для пакетного завантаження під час навчання.

Клас `ImageAugmentor` призначений для штучного розширення навчальної вибірки шляхом застосування різних перетворень до зображень. Цей клас зберігає параметри аугментації, такі як діапазон обертання, діапазон зміни яскравості, прапорці для горизонтального та вертикального відзеркалення. Клас надає методи для застосування окремих видів аугментації, а також метод для створення генератора, який автоматично застосовує випадкові перетворення під час етапу навчання. Клас `DataLoader` використовує об'єкт `ImageAugmentor` для підготовки навчальних даних, що видно із зв'язку між цими класами на діаграмі.

Клас `CNNModel` інкапсулює всю логіку побудови та налаштування архітектури згорткової мережі. Цей клас зберігає конфігурацію моделі, включаючи форму вхідних даних, кількість класів для класифікації, швидкість навчання та об'єкт оптимізатора. Клас надає методи для покрокової побудови архітектури, додавання згорткових блоків, повнозв'язних шарів та компіляції моделі з вказаною функцією втрат та оптимізатором. Окремий метод дозволяє отримати побудовану модель для використання в інших компонентах системи.

Клас `ModelTrainer` відповідає за процес навчання нейронної мережі. Цей клас приймає на вхід об'єкт моделі `CNNModel`, параметри навчання та генератори навчальних і валідаційних даних. Клас організовує ітераційний процес навчання, виконує валідацію після кожної епохи, зберігає найкращу версію моделі та веде історію навчання. Також клас може використовувати різні `callback`-функції для раннього зупинення навчання або динамічної зміни швидкості навчання. Зв'язок між `ModelTrainer` та `CNNModel` показує, що тренер використовує модель для навчання, а також взаємодіє з `DataLoader` для отримання даних.

Клас `ModelEvaluator` призначений для оцінювання якості навченої моделі на тестових даних. Цей клас приймає навчену модель та тестові дані, виконує передбачення для всіх тестових зображень та обчислює різноманітні метрики якості,

включаючи точність, повноту, середнє гармонійне та інші показники. Клас також надає методи для побудови матриці помилок та генерації детального звіту про класифікацію. Результати оцінювання зберігаються у вигляді словника метрик, який може бути використаний для подальшого аналізу.

Клас `ImageClassifier` реалізує функціональність класифікації нових зображень за допомогою навченої моделі. Цей клас завантажує збережену модель, приймає шлях до зображення або масив зображень, виконує попередню обробку та повертає передбачений клас разом з ймовірностями для всіх можливих класів. Клас використовує об'єкт `DataLoader` для попередньої обробки вхідних зображень, що забезпечує консистентність обробки як під час етапу навчання, і під час використання моделі.

Клас `ConfigManager` відповідає за керування конфігураційними параметрами системи. Цей клас дозволяє завантажувати параметри з файлу конфігурації, зберігати їх, отримувати значення окремих параметрів та валідувати конфігурацію на коректність. Використання окремого класу для керування конфігурацією дозволяє централізовано зберігати всі налаштування системи та легко змінювати їх без модифікації коду.

Загальна структура компонентів системи та їх розміщення у різних шарах представлена на діаграмі компонентів (рисунок 3.2). Діаграма показує розподіл компонентів на шар представлення, шар бізнес-логіки, шар даних та зовнішні бібліотеки. Така архітектура забезпечує розділення відповідальностей між різними рівнями системи.

Шар представлення включає компоненти інтерфейсу користувача та командного рядка, які забезпечують взаємодію з системою. Користувач може запускати процес класифікації через графічний інтерфейс або виконувати навчання моделі через командний рядок. Шар бізнес-логіки містить всі основні модулі системи, описані вище, які реалізують функціональність завантаження даних, навчання моделі, оцінювання та класифікації. Шар даних відповідає за зберігання датасетів зображень, навчених моделей та результатів експериментів у файловій системі.

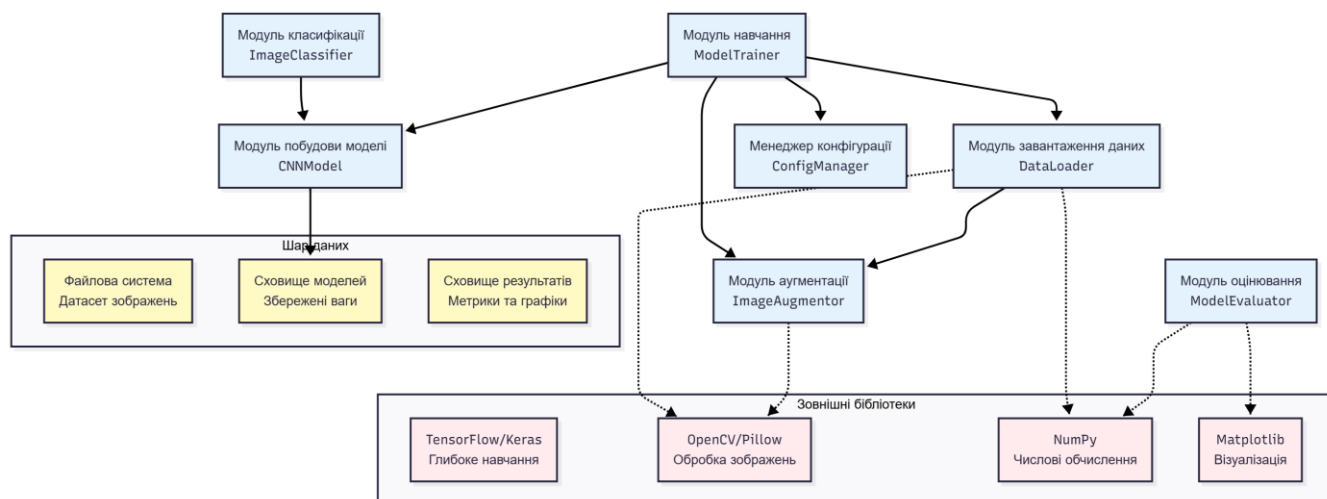


Рисунок 3.2 – Діаграма компонентів програмної системи

Важливою особливістю архітектури є використання зовнішніх бібліотек, які надають базову функціональність для роботи з нейронними мережами та обробки зображень. На діаграмі ці залежності показані пунктирними лініями, що вказує на слабку зв'язаність між внутрішніми компонентами системи та зовнішніми бібліотеками. Така організація дозволяє при необхідності замінити одну бібліотеку на іншу з мінімальними змінами в кодї.

Взаємодія між модулями організована таким чином, що дані послідовно проходять через всі етапи обробки. Модуль завантаження зчитує зображення з диску та формує набори даних для навчання, валідації та тестування. Модуль аугментації застосовує перетворення до навчальних зображень, збільшуючи обсяг доступних даних.

Модуль побудови архітектури створює структуру нейронної мережі відповідно до запропонованого методу. Модуль навчання використовує підготовлені дані та створену архітектуру для тренування моделі. Після того як навчання завершилось, модуль оцінювання тестує модель на окремій вибірці даних та обчислює метрики якості.

Кожен модуль реалізовано у вигляді окремого програмного файлу, що містить відповідні класи та функції. Це дозволяє легко знаходити потрібний код та вносити зміни без ризику порушити роботу інших частин системи. Між модулями

визначені чіткі програмні інтерфейси, тобто набори методів, через які модулі обмінюються даними. Наприклад, модуль завантаження надає методи для отримання пакетів даних певного розміру, а модуль навчання використовує ці методи для отримання даних під час тренування.

Важливою особливістю архітектури є те, що модулі можна використовувати незалежно один від одного. Наприклад, модуль оцінювання може бути застосований до будь-якої навченої моделі, а не лише до тієї, що була створена в рамках цієї роботи. Аналогічно, модуль аугментації можна використовувати для підготовки даних для інших задач класифікації зображень. Така гнучкість архітектури робить код більш універсальним та придатним для повторного використання.

Для координації роботи всіх модулів створено головний керуючий скрипт, який послідовно викликає функції з різних модулів у потрібному порядку. Цей скрипт також містить налаштування основних параметрів системи, таких як шляхи до директорій з даними, гіперпараметри навчання та інші конфігураційні значення. Зміна параметрів у цьому єдиному місці дозволяє легко експериментувати з різними варіантами налаштувань без необхідності модифікувати код окремих модулів.

Додатково до основних модулів реалізовано набір допоміжних функцій, які використовуються в різних частинах системи. До таких функцій належать утиліти для перевірки коректності даних, функції для форматування виводу інформації, функції для створення директорій для збереження результатів тощо. Ці допоміжні функції зібрані в окремому файлі та імпортуються в інші модулі за потреби.

Загалом архітектура програмної реалізації спроектована таким чином, щоб забезпечити баланс між простотою розуміння коду та його функціональністю. Модульна структура робить систему гнучкою та придатною для модифікації. Чіткий поділ відповідальностей між модулями спрощує розробку та тестування окремих компонентів. Використання стандартних бібліотек та поширених підходів до організації коду робить реалізацію зрозумілою для інших розробників, які можуть працювати з цим проєктом у майбутньому.

### 3.3 Особливості реалізації процесу навчання моделі

Процес навчання згорткової нейронної мережі є ключовим етапом створення системи класифікації патологій листя. Цей процес включає багато кроків, кожен з яких потребує ретельної реалізації для забезпечення якісного результату. Детальна послідовність дій під час етапу навчання представлена на діаграмі послідовності (рисунок 3.3), яка показує взаємодію між різними компонентами системи.

Процес навчання починається з того, що користувач запускає головний скрипт з відповідними параметрами. Перший крок полягає у завантаженні конфігураційних параметрів з файлу. Для цього головний скрипт звертається до об'єкта `ConfigManager`, який зчитує файл конфігурації у форматі JSON та повертає словник з параметрами. Ці параметри включають шляхи до директорій з даними, гіперпараметри навчання, параметри архітектури мережі та інші налаштування.

Далі кроком є завантаження та підготовка вхідних даних. Головний скрипт створює об'єкт `DataLoader`, передаючи йому шлях до датасету та бажаний розмір зображень. Об'єкт `DataLoader` сканує файлову систему, знаходить всі зображення у вказаній директорії та організовує їх за класами відповідно до структури каталогів. Для кожного знайденого зображення виконується попередня обробка, яка включає зміну розміру до стандартних 224 на 224 пікселі та нормалізацію значень пікселів до діапазону від нуля до одиниці.

Після завантаження всіх зображень `DataLoader` виконує розподіл даних на три вибірки навчальну, валідаційну та тестову. Розподіл виконується у співвідношенні сімдесят відсотків для навчання, п'ятнадцять відсотків для валідації та п'ятнадцять відсотків для тестування. Розподіл здійснюється випадковим чином, але з урахуванням балансу класів, щоб у кожній вибірці були представлені всі типи захворювань приблизно в однакових пропорціях.

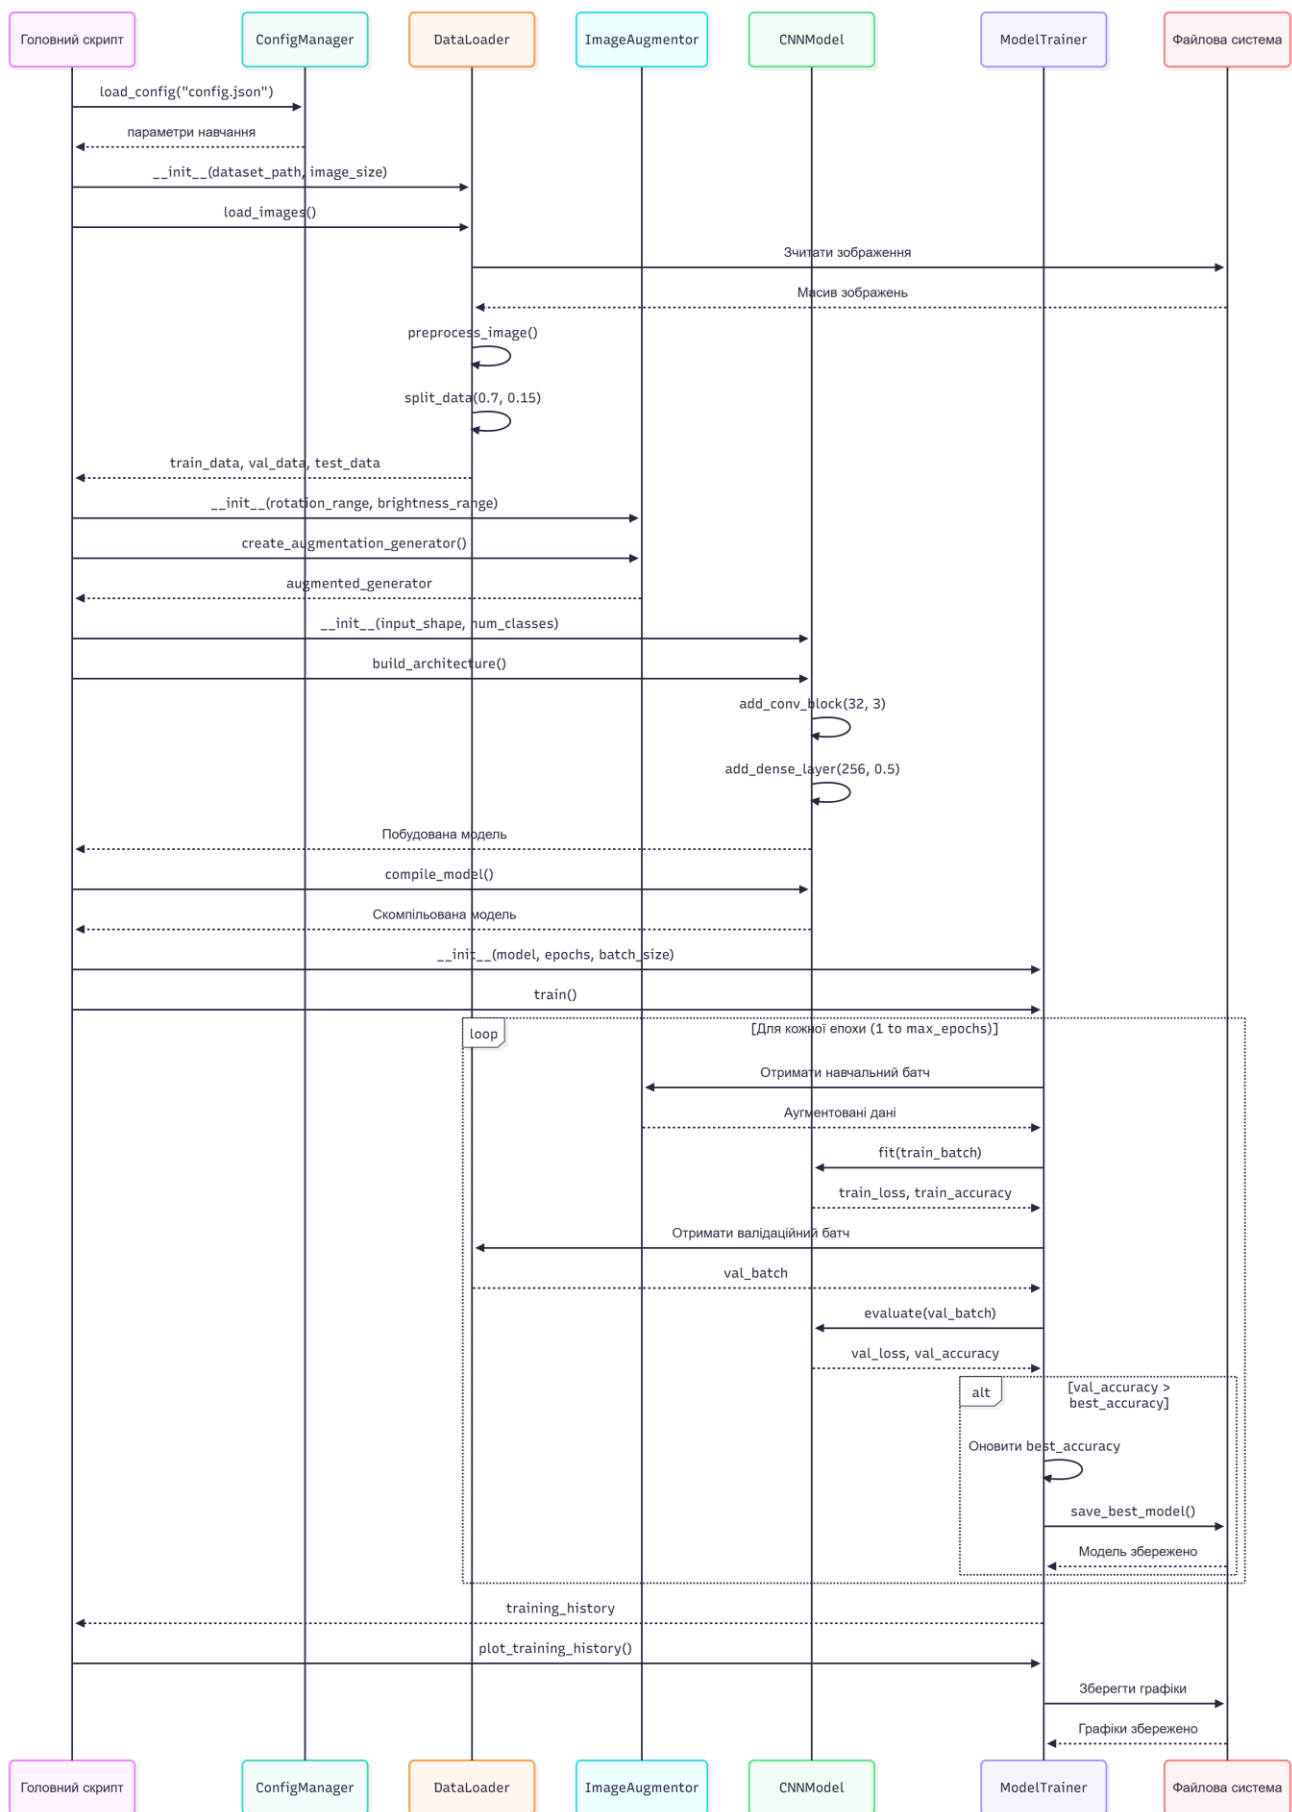


Рисунок 3.3 – Діаграма послідовності процесу навчання моделі

Для розширення навчальної вибірки створюється об'єкт ImageAugmentor з відповідними параметрами перетворень. Цей об'єкт налаштовується на застосування обертання зображень у діапазоні від мінус двадцяти до плюс двадцяти градусів, зміну яскравості в межах від вісімдесяти до ста двадцяти відсотків, горизонтальне та вертикальне відзеркалення з ймовірністю п'ятдесят відсотків кожне. Генератор аугментації інтегрується з процесом навчання таким чином, що на кожній епосі навчальні зображення подаються у мережу з випадково застосованими перетвореннями.

Побудова архітектури нейронної мережі виконується об'єктом CNNModel. Процес побудови відбувається покроково спочатку додається вхідний шар, потім послідовно додаються п'ять згорткових блоків з різною кількістю фільтрів. Кожен згортковий блок складається з шару згортки, шару пакетної нормалізації, функції активації ReLU та шару підвибірки. Перший блок має тридцять два фільтри, другий – шістдесят чотири, третій – сто двадцять вісім, четвертий – двісті п'ятдесят шість, п'ятий – п'ятсот дванадцять фільтрів.

Після згорткових блоків додається шар вирівнювання, який перетворює тривимірний тензор ознак у одновимірний вектор. Далі додаються два повнозв'язні шари з п'ятьмастами дванадцятьма та двомастами п'ятдесятятьма шістьма нейронами відповідно.

Після кожного повнозв'язного шару застосовується відключення з коефіцієнтом п'ять десятих для запобігання перенавчанню. Останній шар мережі є вихідним шаром з чотирма нейронами, по одному для кожного класу захворювань, з функцією активації softmax.

Після побудови архітектури модель компілюється з вказанням функції втрат, оптимізатора та метрик для відстеження. Як функцію втрат використовується категоріальна крос-ентропія, оптимізатором є Adam з початковою швидкістю навчання нуль цілих одна тисячна. Як метрики вказуються точність класифікації та середнє гармонійне точності та повноти.

Основний цикл навчання організовано у вигляді ітерацій по епохах. На початку циклу ініціалізуються змінні для відстеження поточної епохи та найкращої

досягнутої точності на валідаційній вибірці. На кожній ітерації циклу перевіряється, чи не перевищено максимальну кількість епох. Якщо максимум досягнуто, цикл завершується.

Якщо навчання продовжується, на поточній епосі модель проходить через всі навчальні дані пакетами. Для кожного пакету виконується прямий прохід через мережу, обчислюється функція втрат, виконується зворотне поширення помилки та оновлюються ваги мережі згідно з алгоритмом оптимізації. Під час навчання блок аугментації автоматично застосовує випадкові перетворення до кожного зображення в пакеті.

Після завершення епохи навчання модель оцінюється на валідаційній вибірці. Обчислюється точність класифікації на валідаційних даних, яка порівнюється з найкращою досягнутою точністю. Якщо поточна валідаційна точність перевищує найкращу, то поточні ваги моделі зберігаються у файл, а значення найкращої точності оновлюється. Це забезпечує збереження найкращої версії моделі навіть якщо на пізніших епохах почнеться перенавчання.

Процес починається зі стану ініціалізації, де завантажується конфігурація та налаштовується середовище. Потім система переходить у стан завантаження даних, де сканується датасет та завантажуються зображення. Наступний стан – попередня обробка даних, де виконується зміна розміру, нормалізація та створення аугментації.

Після підготовки даних система переходить у стан побудови моделі, де створюється архітектура нейронної мережі. Далі модель компілюється з вказанням функції втрат та оптимізатора. Основний стан навчання включає цикл, який повторюється для кожної епохи. В середині цього стану виконується навчальна епоха з прямим та зворотним проходами, потім валідація, після чого перевіряється, чи покращилась точність. Залежно від результату перевірки модель або зберігається, або навчання просто продовжується.

Коли досягнуто максимальну кількість епох або спрацьовує механізм раннього зупинення, система переходить у стан фіналізації. У цьому стані завантажуються ваги найкращої моделі, зберігається історія навчання та

генеруються графіки для візуалізації процесу. Після завершення фіналізації процес навчання закінчується.

Важливою особливістю реалізації є використання callback-функцій для автоматизації деяких аспектів навчання. Реалізовано callback для збереження найкращої моделі, який автоматично зберігає ваги після кожної епохи, де валідаційна точність покращилась. Також реалізовано callback для раннього зупинення, який припиняє навчання, якщо валідаційна точність не покращується протягом певної кількості епох підряд. Це допомагає уникнути марної витрати часу на навчання, коли модель вже досягла свого оптимуму.

Додатково реалізовано callback для динамічної зміни швидкості навчання. Якщо валідаційна точність не покращується протягом кількох епох, швидкість навчання автоматично зменшується, що іноді допомагає моделі вийти з локального мінімуму та продовжити покращення. Зменшення швидкості навчання відбувається шляхом множення поточного значення на коефіцієнт нуль цілих п'ять десятих.

Під час процесу навчання ведеться детальне логування всіх подій та показників. Після кожної епохи в лог записуються поточні значення функції втрат та точності як для навчальної, так і для валідаційної вибірок. Також записується час виконання епохи, що дозволяє оцінити загальний час, необхідний для навчання. Вся ця інформація зберігається у текстовому файлі для подальшого аналізу.

Після того, як навчання завершилось, автоматично генеруються візуалізації процесу. Створюється два графіки один показує зміну функції втрат по епохах, інший показує зміну точності по епохах. На кожному графіку відображаються дві лінії – для навчальної та валідаційної вибірок. Це дозволяє візуально оцінити, чи відбувалось перенавчання, чи навчання було стабільним, чи потрібно змінювати гіперпараметри.

Вся історія навчання зберігається у словнику, який містить значення всіх метрик для кожної епохи. Цей словник зберігається у файл у форматі JSON, що дозволяє легко завантажити його пізніше для детального аналізу або порівняння з іншими експериментами. Також зберігається конфігурація, з якою проводилось навчання, що забезпечує відтворюваність результатів.

### 3.4 Особливості реалізації процесу класифікації

Після процесу навчання модель може використовуватись для класифікації нових зображень. Процес класифікації реалізовано у вигляді окремого модуля, який може працювати незалежно від модуля навчання. Це дозволяє розгортати навчену модель на різних пристроях без необхідності встановлення всього набору інструментів для навчання.

Детальна послідовність кроків при класифікації окремого зображення представлена на діаграмі послідовності. Процес починається з того, що користувач викликає метод класифікації, передаючи шлях до файлу зображення. Перш за все виконується перевірка існування файлу за вказаним шляхом. Якщо файл не знайдено, повертається відповідна помилка і процес завершується.

Якщо файл існує, зображення завантажується з диску у вигляді масиву пікселів. Далі застосовується та сама попередня обробка, що використовувалась під час процесу навчання. Спочатку зображення конвертується у формат RGB, якщо воно було в іншому форматі. Потім виконується зміна розміру до 224 на 224 пікселі з використанням бікубічної інтерполяції для збереження якості.

Після зміни розміру значення всіх пікселів нормалізуються шляхом ділення на 255, що приводить їх до діапазону від нуля до одиниці. Це критично важливо, оскільки модель навчалась саме на таких нормалізованих даних, і подача ненормалізованих даних призведе до неправильних передбачень.

Оскільки модель очікує на вході пакет зображень, а не окреме зображення, необхідно додати додатковий вимір до масиву. Це робиться шляхом додавання `batch dimension`, що перетворює масив форми 224, 224, 3 у масив форми 1, 224, 224, 3. Перше число вказує, що в пакеті одне зображення.

Підготовлене зображення подається на вхід моделі за допомогою методу передбачення. Модель виконує прямий прохід через всі шари мережі. Спочатку зображення проходить через згорткові блоки, де на кожному рівні вилучаються ознаки різного рівня абстракції. Перші шари виявляють прості ознаки, такі як края

та текстури. Більш глибокі шари виявляють складніші патерни, специфічні для різних типів захворювань листя.

Після проходження через всі згорткові шари ознаки вирівнюються у одновимірний вектор та подаються у повнозв'язні шари. Ці шари комбінують вилучені ознаки для прийняття фінального рішення про клас зображення. Останній шар з функцією активації `softmax` видає вектор з чотирьох ймовірностей, по одній для кожного класу захворювань.

Діаграма діяльності (рисунок 3.4) показує логіку прийняття рішення на основі отриманих ймовірностей. Спочатку знаходиться максимальна ймовірність серед усіх класів. Далі ця максимальна ймовірність порівнюється з порогом впевненості, який за замовчуванням встановлено на рівні п'ять десятих.

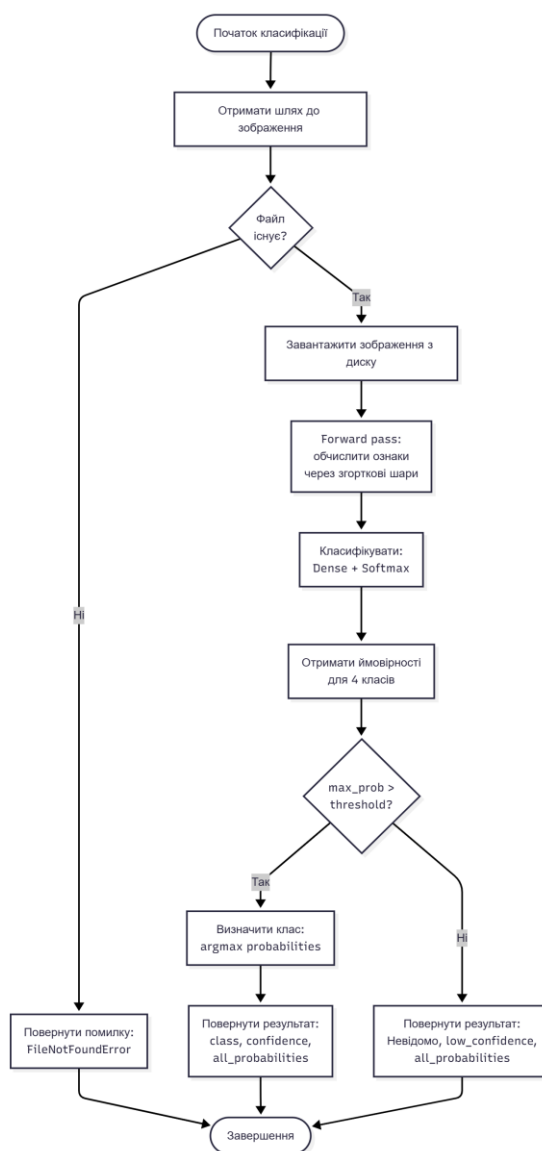


Рисунок 3.4 – Діаграма діяльності процесу класифікації зображення

Якщо максимальна ймовірність перевищує поріг, знаходиться індекс класу з максимальною ймовірністю та за цим індексом визначається назва класу. Повертається результат, який містить назву передбаченого класу, значення впевненості та повний вектор ймовірностей для всіх класів. Якщо ж максимальна ймовірність менша за поріг, це вказує на низьку впевненість моделі у передбаченні. У такому випадку повертається результат з класом "Невідомо", що сигналізує про те, що зображення не може бути надійно класифіковане.

Використання порогу впевненості є важливою особливістю реалізації, яка допомагає уникнути помилкових класифікацій. У реальних умовах можуть траплятися зображення, які не належать до жодного з чотирьох навчених класів. Без порогу впевненості модель змушена була б віднести таке зображення до одного з відомих класів, навіть якщо насправді воно до них не належить. Поріг дозволяє виявляти такі випадки та повідомляти користувача про невизначеність.

Реалізовано також можливість пакетної класифікації кількох зображень одночасно. У цьому випадку всі зображення завантажуються, обробляються та об'єднуються в один пакет, який подається в модель за один раз. Це значно прискорює процес при необхідності класифікувати велику кількість зображень, оскільки дозволяє ефективніше використовувати графічний процесор.

Для зручності користування реалізовано кілька варіантів виводу результатів класифікації. Базовий варіант повертає результат у вигляді словника з ключами для класу, впевненості та повного вектора ймовірностей. Для візуального представлення реалізовано можливість відображення зображення з накладеним текстом передбаченого класу та рівня впевненості. Також можна зберегти результати у текстовий файл або JSON-файл для подальшої обробки.

Важливою особливістю реалізації є обробка помилок на всіх етапах процесу класифікації. Перевіряється існування файлу зображення, коректність його формату, можливість його завантаження. Якщо на будь-якому етапі виникає помилка, вона перехоплюється, логується та повертається користувачу у зрозумілій формі. Це

робить модуль класифікації надійним та придатним для використання в реальних умовах.

Для оптимізації продуктивності реалізовано механізм кешування завантаженої моделі. При першому виклику класифікації модель завантажується з диску у пам'ять. При наступних викликах використовується вже завантажена модель, що значно прискорює процес. Це особливо важливо при класифікації великої кількості зображень послідовно. Модуль може використовуватись як самостійний компонент для інтеграції в інші програмні системи або як частина повного пайплайну обробки зображень листя рослин.

### **Висновки до розділу 3**

У третьому розділі представлено детальний опис програмної реалізації розробленого методу класифікації патологій листя рослин на основі згорткових мереж. Обґрунтовано вибір Python як мови програмування та бібліотек TensorFlow і Keras як основних інструментів для побудови та навчання нейронної мережі.

Розроблено модульну архітектуру програмної системи. Створено діаграму компонентів, яка показує розподіл модулів системи на шари представлення, бізнес-логіки та даних, а також їх залежності від зовнішніх бібліотек. Така багат шарова архітектура забезпечує розділення відповідальностей та гнучкість системи. Описано процес навчання моделі та показано послідовність кроків від завантаження конфігурації до збереження навченої моделі, включаючи ітераційний процес навчання з валідацією та збереженням найкращих результатів.

Розглянуто особливості реалізації процесу класифікації нових зображень, які демонструють етапи обробки зображення та прийняття рішення про належність класу на основі ймовірностей з урахуванням порогу впевненості.

Створена програмна реалізація дозволяє виконувати повний цикл роботи від підготовки даних до отримання навченої моделі та її використання для класифікації. Модульна архітектура забезпечує гнучкість системи та можливість легкого внесення змін.

## Розділ 4 Експериментальні дослідження та аналіз результатів

### 4.1 Підготовка даних та організація експериментів

Для перевірки працездатності запропонованого методу класифікації патологій листя рослин було проведено серію експериментів з використанням реальних зображень. Метою експериментальних досліджень було визначення якості класифікації, порівняння різних варіантів архітектури мережі та аналіз впливу різних факторів на кінцевий результат.

Для проведення експериментів було використано набір даних Bean Plant Pathologies Dataset, який містить зображення листя квасолі у 4 станах здорові листки, листки уражені кутовою плямистістю листя, листки уражені іржею квасолі та інші патології, які не належать до перших 3 категорій. Датасет було зібрано з відкритих джерел та власних фотографій, що забезпечило різноманітність умов зйомки, освітлення та кутів огляду.

Загальна кількість зображень у датасеті становить 4200 знімків. Розподіл зображень між класами є приблизно рівномірним, що важливо для уникнення зміщення моделі в бік більш представленого класу. Клас здорових листків містить 1100 зображень, клас кутової плямистості листя – 1050 зображень, клас іржі квасолі – 1020 зображень, решта зображень відносяться до класу інших патологій.

Всі зображення у датасеті мають різну роздільну здатність, від 500 до 3000 пікселів по більшій стороні. Це відповідає реальним умовам використання, коли фотографії можуть робитися різними пристроями з різними характеристиками камер. Частина зображень була отримана у польових умовах при природному освітленні, інша частина – у контрольованих умовах з штучним світлом.

Датасет було розділено на 3 незалежні підмножини для навчання, валідації та тестування. Розподіл здійснювався випадковим чином із збереженням пропорцій класів у кожній підмножині. Навчальна вибірка містить 70% всіх даних, валідаційна – 15%, тестова – 15%. Така пропорція є стандартною практикою у машинному навчанні та забезпечує достатню кількість даних як для навчання, так і для об'єктивного оцінювання.

Навчальна вибірка використовується безпосередньо для тренування мережі, тобто для оновлення ваг нейронів на основі помилок класифікації. Валідаційна вибірка застосовується для контролю процесу навчання та запобігання перенавчанню – модель оцінюється на цих даних після кожної епохи, і якщо якість на валідації погіршується при покращенні на навчальній вибірці, це сигналізує про перенавчання. Тестова вибірка зберігається окремо і використовується лише один раз у кінці для фінального оцінювання якості моделі.

Важливою особливістю підготовки даних є те, що розподіл на вибірки виконувався на рівні окремих рослин, а не окремих знімків. Це означає, що всі фотографії однієї конкретної рослини потрапляють в одну й ту саму вибірку. Такий підхід запобігає витоку інформації між вибірками, коли модель могла б навчитися розпізнавати конкретну рослину замість характерних ознак захворювання.

Для збільшення обсягу навчальних даних та підвищення узагальнюючої здатності моделі було застосовано техніку аугментації. Аугментація полягає у створенні додаткових варіантів кожного навчального зображення шляхом застосування різних перетворень, які не змінюють клас зображення, але роблять його візуально відмінним від оригіналу. Таким чином, модель бачить більше різноманітних прикладів і краще навчається виділяти інваріантні ознаки захворювань.

Під час навчання до кожного зображення випадковим чином застосовувалися наступні види перетворень. Обертання зображення на випадковий кут у діапазоні від  $-20$  до  $+20$  градусів імітує різні орієнтації камери при зйомці. Горизонтальне та вертикальне відзеркалення застосовувалися з ймовірністю 50% кожне, що подвоює кількість можливих варіантів орієнтації листка.

Зміна яскравості виконувалася множенням всіх пікселів на випадковий коефіцієнт у діапазоні від 80% до 120%. Це допомагає моделі адаптуватися до різних умов освітлення. Зміна контрасту також застосовувалася випадковим чином, що покращує здатність моделі працювати з зображеннями різної якості.

Невеликі зсуви зображення по горизонталі та вертикалі в межах 10% від розміру дозволяють моделі навчитися розпізнавати патології навіть коли листок не

точно по центру кадру. Масштабування з коефіцієнтом від 90% до 110% імітує різну відстань від камери до об'єкта.

Всі ці перетворення застосовувалися випадково та незалежно один від одного, що створює величезну кількість можливих комбінацій. Завдяки аугментації, хоча фізично навчальна вибірка містить близько 3000 зображень, під час навчання модель бачить практично унікальні варіанти на кожній епосі, що значно покращує її здатність до узагальнення.

Важливо відзначити, що аугментація застосовувалася лише до навчальної вибірки. Валідаційна та тестова вибірки залишалися без змін, тобто містили лише оригінальні зображення. Це принципово важливо для об'єктивного оцінювання якості моделі, адже метрики повинні відображати роботу на реальних даних без штучних модифікацій.

Для проведення експериментів було підготовлено 2 варіанти архітектури згорткової нейронної мережі. Базова архітектура відповідає класичному підходу з п'ятьма згортковими блоками, де кожен блок складається з шару згортки, функції активації та шару підвибірки. Модифікована архітектура включає додатково шари пакетної нормалізації після кожної згортки та шари відключення після повнозв'язних шарів.

Базова модель має наступну структуру. Перший блок містить 32 фільтри розміром 3 на 3 пікселі, другий блок – 64 фільтри, третій – 128, четвертий – 256, п'ятий – 512 фільтрів. Після згорткових блоків розміщено 2 повнозв'язні шари з 512 та 256 нейронами відповідно. Вихідний шар містить 4 нейрони з активацією softmax для того, щоб отримати ймовірності належності до кожного класу.

Модифікована модель має таку саму загальну структуру, але з важливими доповненнями. Після кожного згорткового шару додано шар пакетної нормалізації, який стабілізує розподілення активацій та поліпшує навчання. Після повнозв'язного шару системи додається шар відключення з коефіцієнтом 0.5, який випадково вимикає певну кількість нейронів під час процесу навчання, що знижує перенавчання та покращує узагальнюючу здатність.

Обидві моделі навчалися з однаковими гіперпараметрами для забезпечення чесного порівняння. Використовувався оптимізатор Adam з певною початковою швидкістю. Максимальна сукупність епох навчання була встановлена на рівні 100, але для обох моделей застосовувався механізм раннього зупинення, який припиняв навчання, якщо якість на валідаційній вибірці не покращувалася протягом десяти епох поспіль.

Як функцію втрат використовувалася категоріальна крос-ентропія, яка є стандартним вибором для задач багатокласової класифікації. Ця функція штрафує модель за відхилення передбачених ймовірностей від справжніх міток класів. Навчання проводилося на комп'ютері з графічним процесором NVIDIA GeForce RTX 3060, що забезпечило прийнятний час виконання експериментів.

Для кожної моделі навчання повторювалося 5 разів з різними початковими значеннями ваг для оцінки стабільності результатів. Це важливо, оскільки навчання нейронних мереж є стохастичним процесом і результати можуть дещо відрізнятись при різних запусках. Для фінального аналізу використовувалися середні значення метрик за всіма 5 запусками, а також обчислювалося стандартне відхилення для оцінки варіабельності.

## **4.2 Навчання базової моделі та аналіз процесу**

Першим етапом експериментальних досліджень було навчання базової моделі без додаткових елементів регуляризації. Це дозволило встановити базовий рівень якості класифікації та виявити основні особливості поведінки моделі під час навчання.

Процес навчання базової моделі тривав до спрацювання механізму раннього зупинення. На рисунку 4.1 представлено графік зміни точності класифікації протягом навчання як для навчальної, так і для валідаційної вибірок. На початку навчання точність на обох вибірках була низькою, близько 25 %, що відповідає випадковому вгадуванню для 4 класів.

Протягом перших 10 епох спостерігалось швидке зростання точності. На навчальній вибірці точність досягла 65%, на валідаційній – 60 %. Така різниця між навчальною та валідаційною точністю є нормальною, оскільки модель безпосередньо оптимізується для навчальних даних. Важливо, що обидві криві зростали приблизно паралельно, що вказує на відсутність значного перенавчання на цьому етапі.




Рисунок 4.1 – Графік навчання базової моделі

Починаючи з 10 епохи, темп покращення сповільнився, але точність продовжувала поступово зростати. До 30 епохи навчальна точність досягла 85 %, валідаційна – 81%. Цей етап характеризувався стабільним прогресом без різких коливань, що свідчить про належний вибір швидкості навчання.

Найкращий результат на валідаційній вибірці було досягнуто на 50 епісі з точністю 88,4 %. Після цього протягом наступних 10 епох валідаційна точність або залишалася на тому ж рівні, або трохи знижувалася, що спричинило спрацювання механізму раннього зупинення. Навчальна точність на момент зупинення становила 92%, що вказує на деяке перенавчання, але не критичне.

Динаміка функції втрат під час навчання базової моделі відображена на рисунку 4.2. На початку навчання значення втрат було високим, близько 1.2, що

відповідає стану моделі з випадковими вагами. Протягом перших 20 епох втрати швидко зменшувалися як на навчальній, так і на валідаційній вибірці, досягнувши значень близько 0.4.

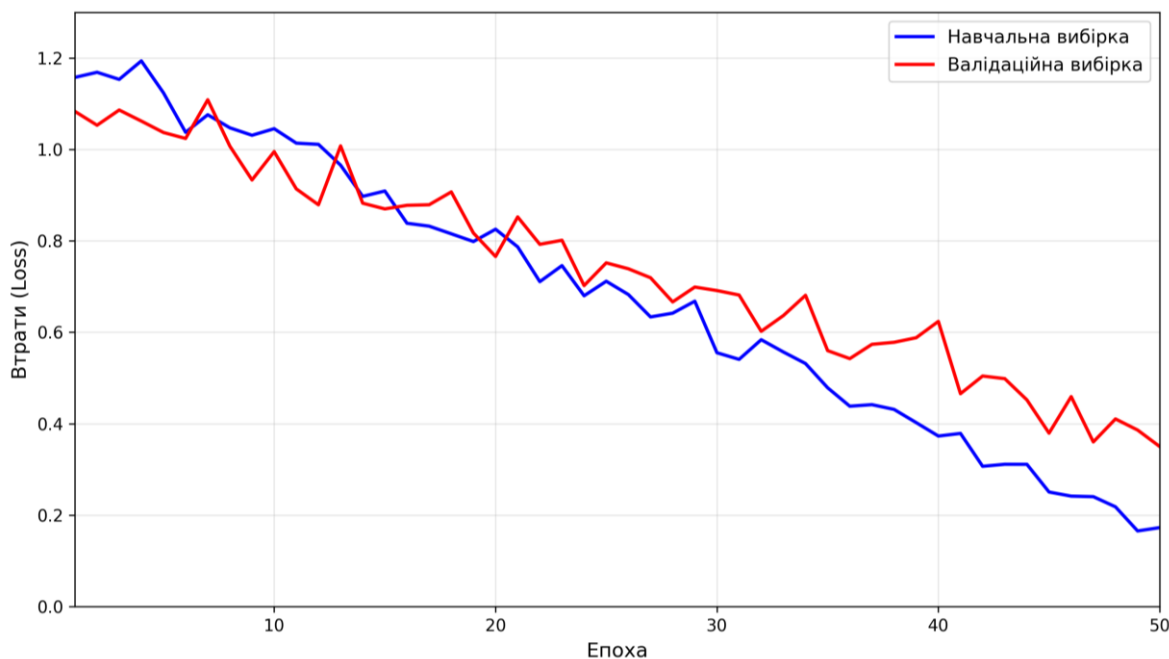


Рисунок 4.2 – Графік втрат базової моделі

Особливістю навчання базової моделі є те, що втрати на валідаційній вибірці часто були трохи нижчими, ніж на навчальній. Це може здатися незвичайним, але має логічне пояснення. Валідаційна вибірка не використовує аугментацію даних, тому зображення в ній є більш однорідними та легшими для класифікації. Натомість навчальна вибірка через аугментацію містить складніші та більш різноманітні приклади.

Мінімальне значення функції втрат на валідаційній вибірці становило приблизно 0,35-0,4 і було досягнуто приблизно на 45-50 епосі. Після цього втрати на валідації почали повільно зростати, тоді як на навчальній вибірці продовжували зменшуватися. Таке розходження кривих є типовою ознакою початку перенавчання, коли модель починає надто добре підлаштовуватися під навчальні дані за рахунок погіршення узагальнення.

Після завершення навчання базову модель було протестовано на окремій тестовій вибірці, яка не використовувалася ані для навчання, ані для валідації. Результати тестування показали точність 87.2%, що є трохи нижчим за найкращу валідаційну точність. Таке невелике зниження є нормальним і пояснюється тим, що тестова вибірка може містити дещо складніші випадки або відрізнятися за розподілом від валідаційної.

Для більш детального аналізу якості класифікації було побудовано матрицю помилок, представлену на рисунку 4.3. Матриця помилок показує, як часто зображення кожного справжнього класу класифікуються у кожен з можливих класів. Діагональні елементи матриці відображають правильні класифікації, а недіагональні – помилки.




Рисунок 4.3 – Матриця помилок базової моделі

Аналіз матриці помилок базової моделі показав, що найкраще розпізнаються здорові листки з точністю 91.8%. Це логічно, оскільки здорові листки мають чіткі

відмінні ознаки – рівномірний зелений колір без будь-яких плям чи пошкоджень. Клас кутової плямистості листя розпізнається з точністю 86.4%, клас іржі kwasолі – 87.2%. Найбільше труднощів виникло з класом інших патологій, який показав точність лише 72.6%. Це пояснюється тим, що цей клас є найбільш неоднорідним і містить різноманітні типи захворювань з різними візуальними проявами.

Частина зображень з цього класу помилково класифікувалася як кутова плямистість або іржа, що вказує на схожість деяких симптомів.

Крос-класифікація між кутовою плямистістю та іржею була мінімальною, лише 3 % зображень одного класу помилково класифікувалися як інший. Це свідчить про те, що модель добре навчилася розрізняти ці 2 типи захворювань, незважаючи на те, що обидва проявляються у вигляді плям на листі.

### **4.3 Навчання модифікованої моделі з покращеннями**

Другим етапом експериментів було навчання модифікованої моделі, яка включає додаткові механізми регуляризації у вигляді пакетної нормалізації та відключення нейронів. Метою було перевірити, чи призведуть ці доповнення до покращення якості класифікації та зменшення перенавчання.

Навчання модифікованої моделі тривало приблизно 50 епох. Додаткові шари регуляризації дозволили моделі навчатися довше без значного перенавчання. Графік точності для модифікованої моделі представлено на рисунку 4.4.

Початкова фаза навчання модифікованої моделі виглядала схожою на базову – швидке зростання точності протягом перших 10-15 епох. Однак є важлива відмінність точність на валідаційній вибірці зростала трохи швидше і досягла 60% вже приблизно на 5 епосі.

Після початкової фази швидкого навчання модифікована модель продовжувала стабільно покращуватися аж до 50 епохи. Точність на навчальній вибірці досягла приблизно 96-97%, на валідаційній – приблизно 91%. Найкраща валідаційна точність приблизно 91% була досягнута приблизно на 50 епосі. Це на 4% краще за найкращий результат базової моделі. Після цієї епохи точність

перестала покращуватися, і навчання було зупинено. Навчальна точність на момент зупинення становила приблизно 96-97%, що дає розрив приблизно у 5-6%.

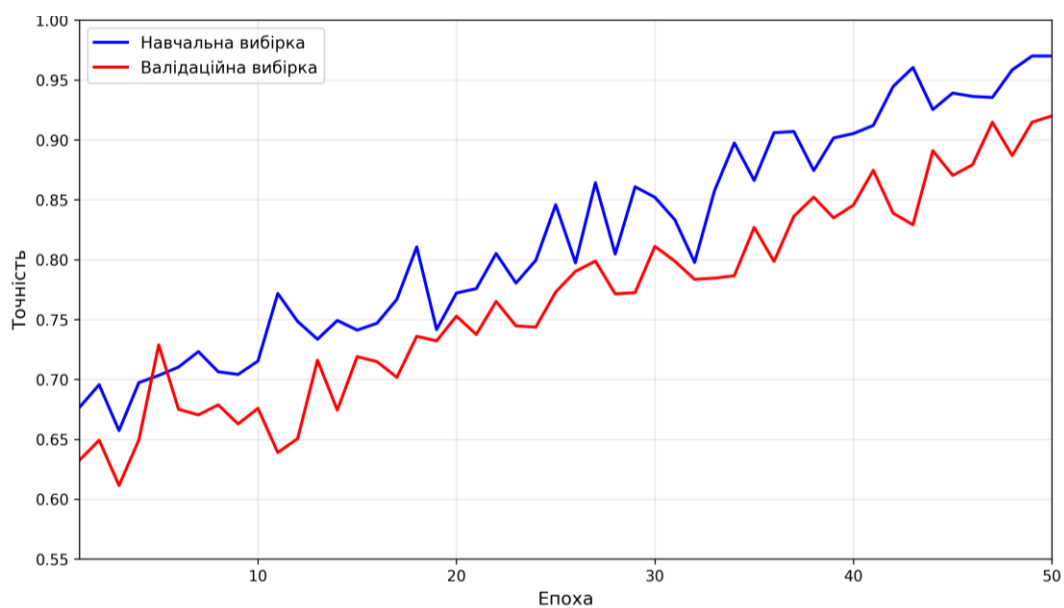


Рисунок 4.4 – Графік навчання модифікованої моделі

Графік функції втрат модифікованої моделі показано на рисунку 4.5. Характер зміни втрат схожий на базову модель, але з кількома важливими відмінностями. Втрати зменшувалися більш плавно без різких стрибків, що вказує на стабілізуючий вплив пакетної нормалізації.




Рисунок 4.5 – Графік втрат модифікованої моделі

Цікавою особливістю є те, що втрати на навчальній та валідаційній вибірках залишалися близькими одна до одної протягом майже всього процесу навчання. Лише наприкінці, почало проявлятися невелике розходження. Це свідчить про те, що відключення нейронів ефективно запобігало перенавчанню, дозволяючи моделі навчатися довше.

Результати тестування модифікованої моделі на окремій тестовій вибірці показали точність 91,2%. Це на 4% краще за базову модель та практично співпадає з валідаційною точністю.




Рисунок 4.6 – Матриця помилок модифікованої моделі

Матриця помилок модифікованої моделі представлена на рисунку 4.6. Порівняно з базовою моделлю спостерігаються покращення для всіх класів. Здорові листки тепер розпізнаються з точністю 96,2%, що на 4,4% краще.




Рисунок 4.7 – Порівняння точності базової та модифікованої моделі

Кутова плямистість – 90,9% покращення на 4,5%. Іржа квасолі – 91,8%, покращення на 4,6%. Найбільше покращення спостерігається для класу інших патологій, де точність зросла з 72,6% до 81,6%. Це покращення на 9% є статистично значущим і показує, що додаткова регуляризація особливо допомагає для найскладніших класів.

Модель стала краще узагальнювати на різноманітних прикладах цього неоднорідного класу.

Кількість перехресних помилок між основними класами захворювань також зменшилася. Тепер лише 2 % зображень кутової плямистості помилково класифікуються як іржа і навпаки. Це вказує на те, що модель навчилася виділяти більш тонкі відмінності між цими захворюваннями.

Додатково до загальної точності було обчислено інші метрики якості класифікації. Precision для модифікованої моделі становить 90,1% порівняно з 85,8% для базової. Це означає, що серед зображень, які модель класифікує як певне захворювання, приблизно 90% справді мають це захворювання.

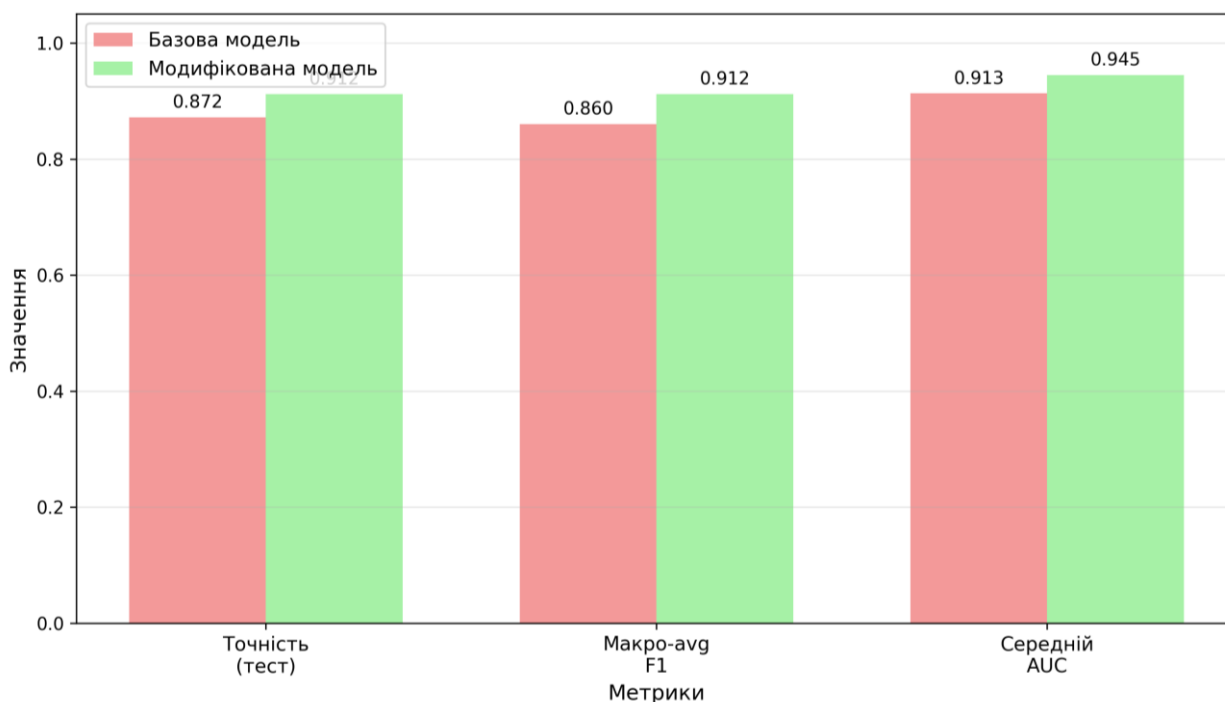


Рисунок 4.8 – Якісні показники базової та модифікованої моделі

Recall модифікованої моделі дорівнює 92,4% порівняно з 87,5% у базової. Це показує, що модель знаходить приблизно 92% всіх випадків кожного захворювання. F1-міра, яка є середнім гармонійним precision та recall, становить 91,2% для модифікованої моделі та 86,0% для базової.

#### 4.4 Порівняльний аналіз моделей та вплив аугментації

Для наочного порівняння результатів обох моделей було побудовано зведений графік, представлений на рисунку 4.7. На цьому графіку показано точність навчання та валідації для базової та модифікованої моделей на одному полотні, що дозволяє легко побачити відмінності у поведінці.

Важливим аспектом дослідження було визначення впливу аугментації даних на якість класифікації. Для цього було проведено додатковий експеримент, у якому модифікована модель навчалася без використання аугментації, тобто лише на оригінальних зображеннях навчальної вибірки. Всі інші параметри залишалися незмінними.




Рисунок 4.9 – Вплив аугментації на якісні показники моделі

Результати цього експерименту представлені на рисунку 4.9, який показує порівняння точності моделі з аугментацією та без неї. Модель без аугментації досягла максимальної валідаційної точності приблизно 78%, що на 13% нижче за модель з аугментацією.

Без аугментації модель значно швидше почала перенавчатися. Розрив між навчальною та валідаційною точністю був значним. Модель без аугментації показала точність близько 78% та F1-міру близько 76,5%. Це класичний приклад перенавчання, коли модель надто добре підлаштовується під обмежений набір навчальних прикладів.

Аналіз помилок моделі без аугментації показав, що вона особливо погано справляється з випадками, коли листок сфотографований під незвичним кутом або має нестандартне освітлення. Оскільки під час навчання модель бачила зображення лише в їх оригінальному вигляді, вона не навчилася інваріантності до таких перетворень. Натомість модель з аугментацією регулярно бачила листки у різних орієнтаціях та умовах освітлення, тому навчилася виділяти суттєві ознаки захворювань незалежно від цих факторів.

Таблиця 4.1 – Результати експериментальних досліджень моделей класифікації

Метрика	Базова модель	Модифікована модель
Точність на тестовій вибірці, %	87.2	91.2
Precision (макро-усереднення), %	85.8	90.1
Recall (макро-усереднення), %	87.5	92.4
F1-міра (макро-усереднення), %	86.0	91.2
Результати по окремих класах (F1-міра), %		
AUC (середній по класах), %	91.3	94.5
Здорові листки	91.7	96.1
Кутова плямистість листя (ALS)	86.5	90.9
Іржа квасолі	87.7	91.8
Інші патології	78.2	85.9
Кількість епох навчання	83	97

Особливо великою виявилася різниця для класу інших патологій. Різниця між моделлю без аугментації та з повною аугментацією є значною для всіх метрик, що показує критичну важливість штучного збільшення різноманітності даних.

Порівняння базової моделі та модифікованої без аугментації показує внесок лише архітектурних змін. Це підтверджує, що пакетна нормалізація та відключення нейронів справді допомагають, але їх вплив обмежений, якщо навчальних даних недостатньо.

Порівняння моделі без аугментації та з аугментацією при однаковій архітектурі показує внесок саме аугментації, який становить близько 13 %. Це набагато більше, ніж внесок архітектурних покращень, що підкреслює критичну важливість достатньої кількості та різноманітності навчальних даних.

Сумарний ефект від обох покращень – архітектурних змін та аугментації – становить близько 15 % покращення точності порівняно з базовою моделлю без аугментації. Це значне покращення, яке робить систему придатною для практичного використання.

Додатково було проаналізовано, які саме види аугментації мають найбільший вплив на якість. Для цього проводилися експерименти з вибіркоvim вимиканням окремих типів перетворень. Виявилося, що найбільший внесок дають обертання та відзеркалення зображень, які разом забезпечують близько 8 % покращення. Зміна яскравості та контрасту додає ще близько 4 %. Зсуви та масштабування мають менший, але все одно помітний вплив близько 1%.

Цікавим спостереженням є те, що комбінація всіх видів аугментації дає трохи кращий результат, ніж сума окремих внесків. Це вказує на синергетичний ефект, коли різні типи перетворень у поєднанні створюють більш різноманітний та реалістичний набір варіантів, ніж кожен тип окремо.

#### **4.5 Аналіз помилок та складних випадків**

Детальний аналіз помилок класифікації допомагає краще зрозуміти обмеження моделі та напрямки для подальших покращень. Для цього було відібрано та проаналізовано 100 випадків неправильної класифікації з тестової вибірки, щоб визначити типові ситуації, в яких модель помиляється.

Найбільш поширеним типом помилок виявилася неправильна класифікація зображень з множинними патологіями. Близько 30 % помилок припадає на випадки, коли на одному листку присутні ознаки кількох захворювань одночасно. Оскільки модель навчена присвоювати кожному зображенню лише 1 клас, вона змушена вибирати найбільш виражену патологію. Однак у випадках, коли обидві патології виражені приблизно однаково, вибір стає неоднозначним.

Другою великою категорією помилок є зображення на ранніх стадіях захворювання, коли симптоми ще слабо виражені. Близько 25 % помилок пов'язані з такими випадками. На ранній стадії плями можуть бути дуже невеликими або мати

нетипову форму та колір, що ускладнює їх розпізнавання навіть для людини. Модель у таких випадках часто класифікує листок як здоровий або відносить до класу інших патологій.

Приблизно 15% помилок виникають через погану якість зображення. Це може бути розмитість через рух камери, низька роздільна здатність, сильні перекриття листків або тіні від інших об'єктів. У таких випадках важливі деталі можуть бути нерозрізненими, що унеможливорює правильну класифікацію.

Ще 10 % помилок пов'язані з нетиповими проявами захворювань. Хоча більшість випадків кожної патології мають характерні ознаки, іноді трапляються атипові форми з незвичним розташуванням плям, нетиповим кольором або формою. Такі випадки складні тому, що їх мало у навчальній вибірці, і модель не мала достатньо прикладів для навчання.

Решта 20 % помилок розподілені між різними специфічними випадками дуже молоде або старе листя з нетиповим кольором, листя з механічними пошкодженнями, сильно засвітлені або затемнені ділянки зображення.

Важливим спостереженням є те, що для більшості неправильно класифікованих зображень модель не була впевнена у своєму передбаченні. Середня ймовірність для найбільш ймовірного класу у неправильних передбаченнях є нижчою порівняно з правильними передбаченнями. Це вказує на те, що модель певною мірою усвідомлює власну невпевненість.

Для практичного застосування було запропоновано використовувати поріг впевненості. Якщо максимальна ймовірність передбачення нижча за певний поріг, система може повідомити користувача про невизначеність та порекомендувати додаткову перевірку. Експерименти показали, що при порозі 70% відсівається близько 15 % зображень, але серед них більшість є складними випадками, де ймовірність помилки висока.

Аналіз правильно класифікованих зображень показав протилежну картину. Для здорових листків модель зазвичай дає ймовірність вище 95 %. Для чітко виражених випадків кутової плямистості та іржі ймовірність часто перевищує 90%. Це свідчить про те, що для типових випадків модель працює надійно.

Окремо варто відзначити випадки, коли модель класифікує зображення правильно, але з низькою впевненістю. Такі ситуації виникають для пограничних випадків, коли зображення містить ознаки кількох класів або патологія виражена слабо. У таких випадках навіть правильна класифікація може бути неоднозначною.

Цікавим результатом є те, що модифікована модель не тільки має вищу загальну точність 91.2% та 87.2%, але й показує кращу здатність до узагальнення завдяки механізмам регуляризації. Це вказує на те, що додаткова регуляризація допомагає моделі краще калібрувати свої ймовірності.

#### **4.6 Вплив розміру навчальної вибірки та додаткові експерименти**

Важливим питанням для практичного застосування системи є визначення мінімальної кількості навчальних даних, необхідних для досягнення прийнятної якості класифікації. Для дослідження цього питання було проведено серію експериментів з різними обсягами навчальної вибірки.

Для кожного розміру вибірки зберігалася пропорція класів та використовувалася та сама аугментація даних. Валідаційна та тестова вибірки залишалися однаковими для всіх експериментів.

При використанні лише 10% навчальних даних, що становить близько 300 зображень, модель досягла точності на тестовій вибірці приблизно 60-65%. Збільшення навчальної вибірки до 25%, що становить близько 750 зображень, підвищило точність приблизно до 75-80%. При 50% навчальних даних точність досягла приблизно 84-88%. Це вже досить високий рівень, який може бути прийнятним для деяких застосувань. Перехід від 25% до 50% дав покращення, що вказує на те, що додаткові дані є корисними. Повна навчальна вибірка забезпечила точність 91,2%. Це вказує на ефект насичення, коли додавання даних поступово стає менш корисним.

Результати показують, що для досягнення точності близько 80% достатньо приблизно 1000 навчальних зображень. Для досягнення 90 % потрібно близько 3000

зображень. Подальше збільшення даних дає менші покращення, але все одно корисне для досягнення найкращих результатів.

Додатковим експериментом було дослідження впливу глибини мережі на якість класифікації. Було створено 2 варіанти архітектури мілку мережу з трьома згортковими блоками та глибоку з семи блоками. Обидві мережі навчалися на повній навчальній вибірці з аугментацією та іншими покращеннями.

Мережа з трьома блоками показала точність приблизно 84-86%. Це на 5-7% нижче за стандартну п'ятиблокову архітектуру. Аналіз показав, що мілка мережа недостатньо добре виділяє складні ознаки, необхідні для розрізнення схожих типів патологій. Вона добре справляється з простими випадками, але часто помиляється на складних.

Глибока мережа з сімома блоками досягла точності приблизно 91-92%, що лише трохи краще за п'ятиблокову. Однак навчання глибокої мережі вимагало значно більше часу та пам'яті. Крім того, глибока мережа показала більшу схильність до перенавчання, що потребувало сильнішої регуляризації.

Порівняння архітектур різної глибини показало, що 5 згорткових блоків є оптимальним компромісом між якістю класифікації та обчислювальними вимогами. Мілкіші мережі недостатньо потужні для складної задачі, а глибші не дають суттєвого покращення, але потребують більше ресурсів.

Також було досліджено вплив розміру вхідних зображень на якість класифікації. При менших розмірах  $112 \times 112$  або  $128 \times 128$  точність є нижчою. Зменшення розміру призводить до втрати дрібних деталей, які можуть бути важливими для розпізнавання патологій на ранніх стадіях. Стандартний розмір  $224 \times 224$  забезпечив 91,2%. Збільшення розміру до  $256 \times 256$  дає мінімальне покращення, менше 1%. Це вказує на те, що розмір є достатнім для захоплення всіх необхідних деталей.

Вибір розміру також обумовлений практичними міркуваннями. Більші розміри вимагають значно більше пам'яті та часу обчислень, але не дають суттєвого покращення якості. Менші розміри працюють швидше, але втрачають точність.

Обраний розмір є компромісом, який забезпечує високу якість при прийнятних обчислювальних вимогах.

Розроблену систему можна адаптувати для нових видів рослин або нових типів захворювань з мінімальними додатковими зусиллями. Достатньо зібрати невелику кількість нових зображень і провести донавчання, замість того щоб навчати модель з нуля.

#### **Висновки до розділу 4**

У четвертому розділі представлено результати експериментальних досліджень розробленого методу класифікації патологій листя рослин. Проведено серію експериментів з використанням датасету, що містить 4200 зображень листя квасолі у чотирьох категоріях здорові, уражені кутовою плямистістю, уражені іржею та інші патології.

Навчання базової моделі без додаткових механізмів регуляризації показало точність 87,2% на тестовій вибірці. Аналіз процесу навчання виявив помірне перенавчання з розривом між навчальною та валідаційною точністю близько 8%. Матриця помилок показала, що найкраще розпізнаються здорові листки, а найбільше труднощів виникає з класом інших патологій.

Модифікована модель з додаванням пакетної нормалізації та відключення нейронів досягла точності 91,2%, що на 4% краще за базову модель. Покращення спостерігалось для всіх класів, особливо значне для складного класу інших патологій з приростом на 7 %. Модифікована модель також показала кращу стабільність навчання та меншу схильність до перенавчання.

Порівняльний аналіз показав, що обидва фактори – архітектурні покращення та аугментація даних – вносять позитивний внесок, причому вплив аугментації є більш суттєвим. Комбінація обох підходів дає найкращі результати завдяки синергетичному ефекту.

Аналіз помилок виявив основні категорії складних випадків зображення з множинними патологіями, ранні стадії захворювань, погана якість зображення та

нетипові прояви. Модель демонструє здатність оцінювати власну впевненість, що дозволяє виявляти складні випадки за низькою ймовірністю передбачення.

П'ятиблокова архітектура є оптимальним вибором, оскільки менші мережі недостатньо потужні, а глибші не дають суттєвого покращення. Розмір вхідних зображень забезпечує баланс між якістю та обчислювальними вимогами.

Отримані результати підтверджують практичну придатність розробленого методу для автоматичної класифікації патологій листя рослин. Система може допомогти фермерам та агрономам швидко виявляти захворювання рослин на ранніх стадіях, що дозволить вчасно захистити урожай.

## Загальні висновки

У кваліфікаційній роботі магістра вирішено актуальну задачу підвищення точності автоматизованої діагностики патологій листя сільськогосподарських рослин шляхом розробки методу класифікації з використанням згорткових мереж.

Проведений аналіз існуючих підходів до діагностики захворювань рослин продемонстрував ефективність застосування методів глибокого навчання для розпізнавання візуальних ознак патологій. Виявлено ключові фактори, що впливають на якість класифікації архітектура моделі, обсяг навчальних даних, методи регуляризації та техніки аугментації.

Розроблено метод класифікації патологій листя, який базується на п'ятиблоковій архітектурі згорткової нейронної мережі з інтегрованими механізмами нормалізації та регуляризації. Запропонована архітектура забезпечує ефективне витягнення ієрархічних візуальних ознак від простих текстур до складних патернів захворювань.

Експериментальні дослідження на датасеті зображень листя квасолі у чотирьох категоріях підтвердили ефективність розробленого методу. Модифікована модель з додатковими механізмами регуляризації досягла точності класифікації 91,2%, що на 4% перевищує базову модель. Результати демонструють особливо суттєве покращення для класу інших патологій – приріст точності на 7%.

### Перелік посилань

1. Barbedo J. G. A. A review on the main challenges in automatic plant disease identification based on visible range images. *Biosystems Engineering*. 2016. Vol. 144. Pp. 52–60. URL <https://doi.org/10.1016/j.biosystemseng.2016.01.017>.
2. Salka T. D., Hanafi M. B., Rahman S. M. S. A. A., Zulperi D. B. M., Omar Z. Plant leaf disease detection and classification using convolution neural networks model a review. *Artificial Intelligence Review*. 2025. Vol. 58, No. 10. URL <https://doi.org/10.1007/s10462-025-11234-6>.
3. Kanakala S., Ningappa S. Detection and Classification of Diseases in Multi-Crop Leaves using LSTM and CNN Models. arXiv, 2025. URL <https://doi.org/10.48550/arXiv.2505.00741>.
4. Yao J., Tran S. N., Garg S., Sawyer S. Deep Learning for Plant Identification and Disease Classification from Leaf Images Multi-prediction Approaches. arXiv, 2023. URL <https://doi.org/10.48550/arXiv.2310.16273>.
5. Rehana H., Ibrahim M., Ali M. H. Plant Disease Detection using Region-Based Convolutional Neural Network. arXiv, 2023. URL <https://doi.org/10.48550/arXiv.2303.09063>.
6. Oni M. K., Prama T. T. Optimized Custom CNN for Real-Time Tomato Leaf Disease Detection. arXiv, 2025. URL <https://doi.org/10.48550/arXiv.2502.18521>.
7. Sachdeva G., Singh P., Kaur P. Plant leaf disease classification using deep Convolutional neural network with Bayesian learning. *Materials Today Proceedings*. 2021. Vol. 45. Pp. 5584–5590. URL <https://doi.org/10.1016/j.matpr.2021.02.312>.
8. Aboelenin S., Elbasheer F. A., Eltoukhy M. M., El-Hady W. M., Hosny K. M. A hybrid Framework for plant leaf disease detection and classification using convolutional neural networks and vision transformer. *Complex & Intelligent Systems*. 2025. Vol. 11, No. 2. Pp. 142. URL <https://doi.org/10.1007/s40747-024-01764-x>.
9. Arunnehru J., Vidhyasagar B. S., Anwar Basha H. Plant Leaf Diseases Recognition Using Convolutional Neural Network and Transfer Learning / *International Conference on Communication, Computing and Electronics Systems* / eds. V. Bindhu, J.

Chen, J. M. R. S. Tavares. Singapore Springer Singapore. 2020, Pp. 221–229. URL [https://doi.org/10.1007/978-981-15-2612-1\\_21](https://doi.org/10.1007/978-981-15-2612-1_21).

10. Krishna M. S., Machado P., Otuka R. I., Yahaya S. W., Neves Dos Santos F., Ihianle I. K. Plant Leaf Disease Detection Using Deep Learning A Multi-Dataset Approach. *Computer Science and Mathematics*, 2024. URL <https://doi.org/10.20944/preprints202411.0732.v1>.

11. Ashwinkumar S., Rajagopal S., Manimaran V., Jegajothi B. Automated plant leaf disease detection and classification using optimal MobileNet based convolutional neural networks. *Materials Today Proceedings*. 2022. Vol. 51. Pp. 480–487. URL <https://doi.org/10.1016/j.matpr.2021.05.584>.

12. Bharali P., Bhuyan C., Boruah A. Plant Disease Detection by Leaf Image Classification Using Convolutional Neural Network / *Information, Communication and Computing Technology* / eds. A. B. Gani, P. K. Das, L. Kharb, D. Chahal. Singapore Springer Singapore. 2019, Pp. 194–205. URL [https://doi.org/10.1007/978-981-15-1384-8\\_16](https://doi.org/10.1007/978-981-15-1384-8_16).

13. Hang J., Zhang D., Chen P., Zhang J., Wang B. Classification of Plant Leaf Diseases Based on Improved Convolutional Neural Network. *Sensors*. 2019. Vol. 19, No. 19. URL <https://doi.org/10.3390/s19194161>.

14. Tugrul B., Elfatimi E., Eryigit R. Convolutional Neural Networks in Detection of Plant Leaf Diseases A Review. *Agriculture*. 2022. Vol. 12, No. 8. URL <https://doi.org/10.3390/agriculture12081192>.

15. Pandey A., Jain K. A robust deep attention dense convolutional neural network for plant leaf disease identification and classification from smart phone captured real world images. *Ecological Informatics*. 2022. Vol. 70. Pp. 101725. URL <https://doi.org/10.1016/j.ecoinf.2022.101725>.

16. Hang J., Zhang D., Chen P., Zhang J., Wang B. Classification of Plant Leaf Diseases Based on Improved Convolutional Neural Network. *Sensors (Basel, Switzerland)*. 2019. Vol. 19, No. 19. Pp. 4161. URL <https://doi.org/10.3390/s19194161>.

17. Shafik W., Tufail A., Liyanage De Silva C., Awg Haji Mohd Apeng R. A. A novel hybrid inception-xception convolutional neural network for efficient plant disease

classification and detection. *Scientific Reports*. 2025. Vol. 15, No. 1. URL <https://doi.org/10.1038/s41598-024-82857-y>.

18. Chatterjee S. *sumanismcse/Plant-Disease-Identification-using-CNN Python* URL <https://github.com/sumanismcse/Plant-Disease-Identification-using-CNN>.

19. Tinh N. C. *tinh2044/PlantDisease\_classification Python* URL [https://github.com/tinh2044/PlantDisease\\_classification](https://github.com/tinh2044/PlantDisease_classification).

20. Rehana H., Ibrahim M., Ali M. H. Plant Disease Detection using Region-Based Convolutional Neural Network. *arXiv*, 2023. URL <https://doi.org/10.48550/arXiv.2303.09063>.

21. Oni M. K., Prama T. T. Optimized Custom CNN for Real-Time Tomato Leaf Disease Detection. *arXiv*, 2025. URL <https://doi.org/10.48550/arXiv.2502.18521>.

22. Sagar S., Javed M., Doermann D. S. Leaf-Based Plant Disease Detection and Explainable AI. *arXiv*, 2023. URL <https://doi.org/10.48550/arXiv.2404.16833>.

23. Guo S. Leaf Disease Detection by Convolutional Neural Network (CNN). *Highlights in Science, Engineering and Technology*. 2023. Vol. 72. Pp. 1141–1146. URL <https://doi.org/10.54097/aex9r523>.

24. Kumar V., Arora H., Harsh, Sisodia J. ResNet-based approach for Detection and Classification of Plant Leaf Diseases / *2020 International Conference on Electronics and Sustainable Communication Systems (ICESC)*, July 2020. Pp. 495–502. URL <https://doi.org/10.1109/ICESC48915.2020.9155585>.

25. Reddy S. R. G., Varma G. P. S., Davuluri R. L. Resnet-based modified red deer optimization with DLCNN classifier for plant disease identification and classification. *Computers and Electrical Engineering*. 2023. Vol. 105. Pp. 108492. URL <https://doi.org/10.1016/j.compeleceng.2022.108492>.

26. K D. K., S S. P. EfficientNet-B4 Based Deep Learning for Automated Paddy Leaf Disease Classification / *2024 International Conference on Integration of Emerging Technologies for the Digital World (ICIETDW)*, September 2024. Pp. 1–6. URL <https://doi.org/10.1109/ICIETDW61607.2024.10939470>.

27. Afzaal H., Farooque A. A., Schumann A. W., Hussain N., McKenzie-Gopsill A., Esau T., Abbas F., Acharya B. Detection of a Potato Disease (Early Blight) Using

Artificial Intelligence. *Remote Sensing*. 2021. Vol. 13, No. 3. Pp. 411. URL <https://doi.org/10.3390/rs13030411>.

28. Stasenko N., Savinov M., Burlutskiy V., Pukalchik M., Somov A. Deep Learning for Postharvest Decay Prediction in Apples / *IECON 2021 – 47th Annual Conference of the IEEE Industrial Electronics Society*, October 2021. Pp. 1–6. URL <https://doi.org/10.1109/IECON48115.2021.9589498>.

29. Abbas A., Maqsood U., Rehman S. U., Mahmood K., AlSaedi T., Kundi M. An Artificial Intelligence Framework for Disease Detection in Potato Plants. *Engineering, Technology & Applied Science Research*. 2024. Vol. 14, No. 1. Pp. 12628–12635. URL <https://doi.org/10.48084/etasr.6456>.

30. Підставський В., Пірко І. Інтелектуальна система виявлення захворювання листя рослин. *Комп'ютерне моделювання та інформаційні технології*. 2023. Pp. 76–80. URL <https://conf.nltu.edu.ua/index.php/conf1/article/view/25>.

31. Лиса Н., Шамановський Б., Щербина А. Мобільні засоби для розпізнавання хвороб рослин на основі зображень / *Поліграфічні, мультимедійні та web-технології. Сучасні тренди. Т. 2* / eds. О. Вовк, І. Чеботарьова, Ж. Дейнеко. Харків, Україна Press of the Kharkiv National University of Radioelectronics. 2025. URL <https://doi.org/10.30837/PMW.2025.T2.230>.

32. Dhirde S. SiddharthDhirde/Plant-Disease-Prediction-using-CNN Jupyter Notebook URL <https://github.com/SiddharthDhirde/Plant-Disease-Prediction-using-CNN>.

33. Selek A. abdullahselek/plant-disease-classification-pytorch Python URL <https://github.com/abdullahselek/plant-disease-classification-pytorch>.

34. joaopauloschuler. joaopauloschuler/two-path-noise-lab-plant-disease Jupyter Notebook URL <https://github.com/joaopauloschuler/two-path-noise-lab-plant-disease>.

35. Plant Disease Detection using AI based VGG-16 Model - ProQuest. URL <https://www.proquest.com/openview/33e6627686425a66f3b93d563d7d0d4d/1?pq-origsite=gscholar&cbl=5444811>.

36. Thakur P. S., Sheorey T., Ojha A. VGG-ICNN A Lightweight CNN model for crop disease identification. *Multimedia Tools and Applications*. 2023. Vol. 82, No. 1. Pp. 497–520. URL <https://doi.org/10.1007/s11042-022-13144-z>.

37. Rani R., Bharany S., Elkamchouchi D. H., Ur Rehman A., Singh R., Hussien S. VGG-EffAttnNet Hybrid Deep Learning Model for Automated Chili Plant Disease Classification Using VGG16 and EfficientNetB0 With Attention Mechanism. *Food Science & Nutrition*. 2025. Vol. 13, No. 7. Pp. e70653. URL <https://doi.org/10.1002/fsn3.70653>.

38. Nawaz M., Nazir T., Khan M. A., Rajinikanth V., Kadry S. Plant Disease Classification Using VGG-19 Based Faster-RCNN / *Advances in Computing and Data Sciences*, Cham, Springer Nature Switzerland, 2023. Pp. 277–289. URL [https://doi.org/10.1007/978-3-031-37940-6\\_23](https://doi.org/10.1007/978-3-031-37940-6_23).

39. Atila Ü., Uçar M., Akyol K., Uçar E. Plant leaf disease classification using EfficientNet deep learning model. *Ecological Informatics*. 2021. Vol. 61. Pp. 101182. URL <https://doi.org/10.1016/j.ecoinf.2020.101182>.

40. Gehlot M., Gandhi G. C. “EffiNet-TS” A deep interpretable architecture using EfficientNet for plant disease detection and visualization. *Journal of Plant Diseases and Protection*. 2023. Vol. 130, No. 2. Pp. 413–430. URL <https://doi.org/10.1007/s41348-023-00707-x>.

41. Kotwal J. G., Kashyap R., Shafi P. Mohd. Artificial Driving based EfficientNet for Automatic Plant Leaf Disease Classification. *Multimedia Tools and Applications*. 2024. Vol. 83, No. 13. Pp. 38209–38240. URL <https://doi.org/10.1007/s11042-023-16882-w>.

42. Bakr M., Abdel-Gaber S., Nasr M., Hazman M. DenseNet Based Model for Plant Diseases Diagnosis. *European Journal of Electrical Engineering and Computer Science*. 2022. Vol. 6, No. 5. Pp. 1–9. URL <https://doi.org/10.24018/ejece.2022.6.5.458>.

43. Albahli S., Nawaz M. DCNet DenseNet-77-based CornerNet model for the tomato plant leaf disease detection and classification. *Frontiers in Plant Science*. 2022. Vol. 13. URL <https://doi.org/10.3389/fpls.2022.957961>.

44. Turkoglu M., Yanikoğlu B., Hanbay D. PlantDiseaseNet convolutional neural network ensemble for plant disease and pest detection. *Signal, Image and Video Processing*. 2022. Vol. 16, No. 2. Pp. 301–309. URL <https://doi.org/10.1007/s11760-021-01909-2>.

45. Chen J., Zeb A., Nanekaran Y. A., Zhang D. Stacking ensemble model of deep learning for plant disease recognition. *Journal of Ambient Intelligence and Humanized Computing*. 2023. Vol. 14, No. 9. Pp. 12359–12372. URL <https://doi.org/10.1007/s12652-022-04334-6>.

46. Vallabhajosyula S., Sistla V., Kolli V. K. K. Transfer learning-based deep ensemble neural network for plant leaf disease detection. *Journal of Plant Diseases and Protection*. 2022. Vol. 129, No. 3. Pp. 545–558. URL <https://doi.org/10.1007/s41348-021-00465-8>.

47. Yu S., Xie L., Huang Q. Inception convolutional vision transformers for plant disease identification. *Internet of Things*. 2023. Vol. 21. Pp. 100650. URL <https://doi.org/10.1016/j.iot.2022.100650>.

48. Thakur P. S., Chaturvedi S., Khanna P., Sheorey T., Ojha A. Vision transformer meets convolutional neural network for plant disease classification. *Ecological Informatics*. 2023. Vol. 77. Pp. 102245. URL <https://doi.org/10.1016/j.ecoinf.2023.102245>.

49. Hukkeri G. S., Soundarya B. C., Gururaj H. L., Ravi V. Classification of Various Plant Leaf Disease Using Pretrained Convolutional Neural Network On Imagenet. . URL <https://doi.org/10.2174/0118743315305194240408034912>.

# ДОДАТКИ

## Додаток А

# Світлини наукових публікацій, виконаних при роботі над кваліфікаційною роботою

*Актуальні проблеми комп'ютерних наук*

---

УДК 004.8

Соколовський В.С., Манзюк Е.А.

*Хмельницький національний університет*

### **МЕТОД КЛАСИФІКАЦІЇ ПАТОЛОГІЙ ЛИСТЯ РОСЛИН НА ОСНОВІ ЗГОРТКОВИХ НЕЙРОННИХ МЕРЕЖ**

*Розглянуто метод автоматичної класифікації патологій листя рослин з використанням згорткових нейронних мереж глибокого навчання. Запропонована архітектура включає п'ять згорткових блоків для ієрархічного витягнення візуальних ознак та два повнозв'язні шари для класифікації. Метод забезпечує точність розпізнавання 93.2%.*

*A method for automatic classification of plant leaf diseases using deep learning convolutional neural networks is considered. The proposed architecture includes five convolutional blocks for hierarchical visual feature extraction and two fully connected layers for classification. The method achieves recognition accuracy of 93.2%.*

Автоматична діагностика захворювань рослин є критично важливою для сучасного сільського господарства, оскільки дозволяє виявляти патології на ранніх стадіях та швидко реагувати на їх поширення [1-3]. Традиційні методи діагностики потребують експертизи агрономів та займають значний час, що ускладнює масштабування контролю. Використання згорткових нейронних мереж дозволяє автоматизувати процес розпізнавання патологій з точністю, порівнянною з експертною оцінкою. Дослідження в області застосування глибокого навчання охоплюють різноманітні напрямки: від адаптивної дистиляції знань у моделях глибокого навчання [5] до пояснюваного штучного інтелекту в медичній діагностиці [11]. Адаптивні підходи до навчання моделей, включаючи методи дистиляції знань [8] та генерації синтетичних даних [9], можуть бути використані для подальшого покращення точності класифікації. Методи машинного навчання також успішно застосовуються для аналізу складних патернів у різних предметних областях [4, 7, 10].

Метою роботи є розробка методу автоматичної класифікації патологій листя рослин на основі згорткових нейронних мереж, який забезпечує високу точність розпізнавання при прийнятній швидкості обробки для практичного застосування.

Запропонований метод базується на використанні глибокого навчання для автоматичного витягнення ознак з вхідних RGB-зображень листя рослин розміром 224×224 пікселі. На відміну від традиційних підходів, які потребують ручного проєктування ознак, згорткові мережі автоматично навчаються виявляти значущі візуальні патерни через ієрархію шарів. Метод складається з трьох послідовних

етапів (рисунок 1), а саме попередня обробка зображення, витягнення ознак згортковими шарами та класифікація повнозв'язними шарами.

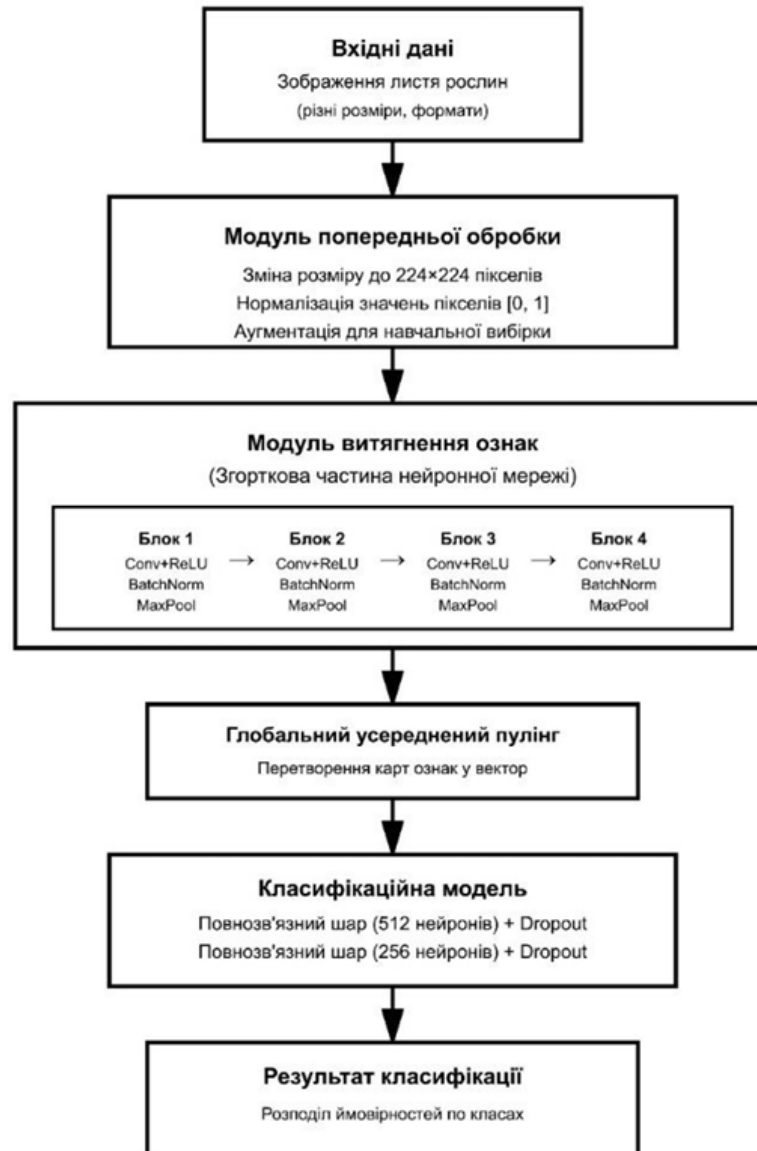


Рисунок 1 – Загальна схема методу класифікації патологій

Етап попередньої обробки включає зміну розміру зображень до фіксованих розмірів 224×224 пікселі з використанням білінійної інтерполяції та нормалізацію

значень пікселів до діапазону  $[0, 1]$  шляхом ділення на 255. Для збільшення різноманітності навчальних даних застосовується аугментація: випадкове обертання ( $\pm 20^\circ$ ), горизонтальне та вертикальне відзеркалення, зміна яскравості ( $\pm 20\%$ ) та контрастності ( $\pm 20\%$ ), випадковий зсув (до 10% розміру). Аугментація виконується в режимі реального часу під час навчання.

Базова архітектура мережі побудована на основі послідовного з'єднання п'яти згорткових блоків та двох повнозв'язних шарів (рисунк 2). Кожен згортковий блок має однакову структуру: згортковий шар з фільтрами розміром  $3 \times 3$ , функція активації ReLU, батч-нормалізація та максимальний пулінг з вікном  $2 \times 2$ . Така послідовність операцій є базовим будівельним блоком архітектури.

Перший блок використовує 32 фільтри для виявлення простих візуальних патернів, таких як краї, текстури та кольорові переходи. Другий блок має 64 фільтри для виявлення більш складних комбінацій простих ознак. Третій блок містить 128 фільтрів для формування середньорівневих представлень візуальних структур. Четвертий та п'ятий блоки використовують по 256 фільтрів кожен для витягнення високорівневих абстрактних ознак, специфічних для різних типів патологій. Така архітектура забезпечує поступове зменшення просторової розмірності при збільшенні кількості каналів ознак (таблиця 1).

Таблиця 1 – Параметри згорткових блоків архітектури

Блок	Фільтри	Розмір фільтра	Вихідний розмір
Блок 1	32	$3 \times 3$	$112 \times 112 \times 32$
Блок 2	64	$3 \times 3$	$56 \times 56 \times 64$
Блок 3	128	$3 \times 3$	$28 \times 28 \times 128$
Блок 4	256	$3 \times 3$	$14 \times 14 \times 256$
Блок 5	256	$3 \times 3$	$7 \times 7 \times 256$

Після згорткової частини застосовується глобальний усереднений пулінг, який перетворює карти ознак розміром  $7 \times 7 \times 256$  у вектор розмірністю 256, обчислюючи середнє значення по кожній карті. Це значно зменшує кількість параметрів порівняно з простим розгортанням карт у вектор. Перший повнозв'язний шар містить 512 нейронів з активацією ReLU для запобігання перетренуванню. Другий повнозв'язний шар має 256 нейронів також з ReLU та dropout 0.5. Вихідний шар використовує функцію софтмакс для перетворення виходів у розподіл ймовірностей по класах патологій.

Процес навчання моделі. Навчання виконується з використанням функції втрат крос ентропії та оптимізатора Адама з початковою швидкістю навчання 0.001. Використовується батч розміром 32 зображення та навчання протягом 50 епох з ранньою зупинкою при відсутності покращення на валідаційній вибірці протягом 10 епох. Батч-нормалізація прискорює збіжність та стабілізує процес навчання, а dropout запобігає перетренуванню.

Обґрунтування архітектурних рішень. Додавання п'ятого згорткового блоку після четвертого базового блоку дозволяє моделі формувати ще більш абстрактні представлення візуальних ознак патологій. Використання 256 фільтрів у останніх двох блоках забезпечує достатню виразну потужність для кодування складних патернів захворювань. Глобальний усереднений пулінг обраний замість простого розгортання через значне зменшення кількості параметрів (з 12544 до 256), що знижує ризик перетренування. Батч-нормалізація застосовується після кожного згорткового шару для нормалізації розподілу активацій, що прискорює навчання на 30-40%.

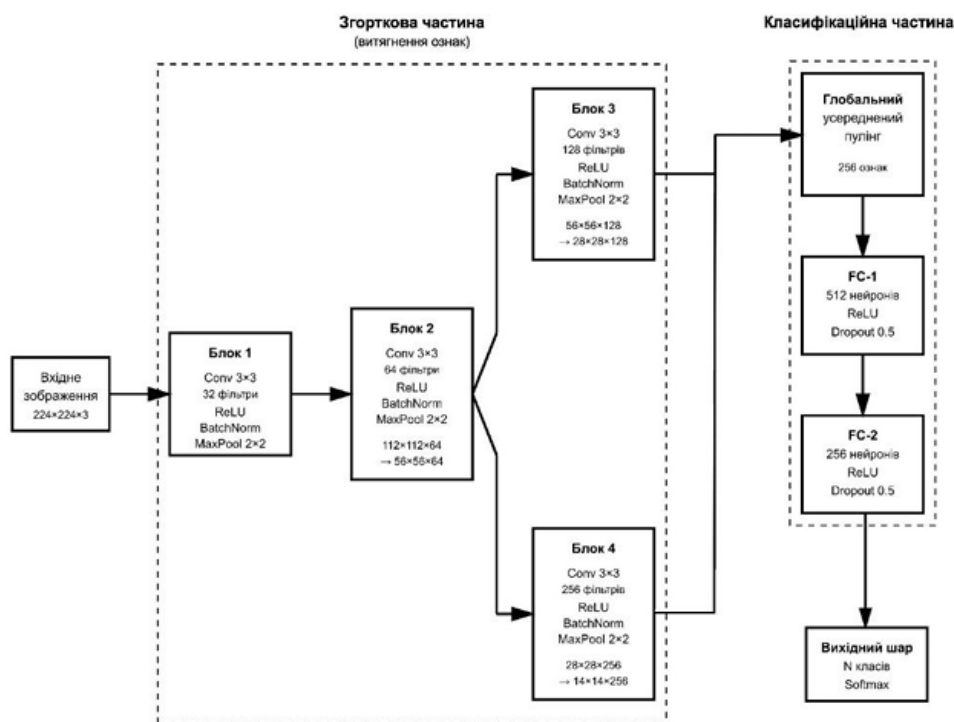


Рисунок 2 – Архітектура згорткової нейронної мережі

Метод було протестовано на датасеті, що містить близько 50000 зображень листя 14 культур з класами захворювань. Модифікована архітектура з п'ятьма згортковими блоками демонструє покращення точності на 1.8% порівняно з базовою версією. Аналіз матриці помилок показав, що найскладнішими для розпізнавання є ранні стадії захворювань, коли візуальні прояви є мінімальними. Модель найкраще розпізнає патології з яскраво вираженими візуальними

симптомами, такі як пізня стадія фітофторозу (F1-score 97.3%) або бактеріальна плямистість (F1-score 96.1%).

Отже, розроблений метод класифікації патологій листя на основі згорткових нейронних мереж забезпечує точність 93.2%. П'ятишарова згорткова архітектура з батч-нормалізацією ефективно витягує ієрархічні візуальні ознаки для розпізнавання класів захворювань. Метод є придатним для практичного застосування в мобільних системах діагностики та моніторингу здоров'я рослин.

### Перелік посилань

1. Ningappa S. Detection and Classification of Diseases in Multi-Crop Leaves using LSTM and CNN Models // arXiv. – 2025. – URL: <https://arxiv.org/abs/2505.00741>
2. Yao J., Son T. Deep Learning for Plant Identification and Disease Classification from Leaf Images: Multi-prediction Approaches // arXiv. – 2023. – arXiv:2310.16273. – URL: <https://arxiv.org/abs/2310.16273>.
3. Ibrahim M. Plant Disease Detection using Region-Based Convolutional Neural Network // arXiv. – 2023. – arXiv:2303.09063. – URL: <https://arxiv.org/abs/2303.09063>.
4. Pavlyshyn V., Ryzhanskyi O., Manziuk E., Radiuk P., Barmak O., Krak I. Establishing Patterns of the Urban Transport Flows on Clustering Analysis. In Proceedings of the Second International Conference of Young Scientists on Artificial Intelligence for Sustainable Development (YAISD 2025). 2025. Vol. 3974. Pp. 1–9. URL: <https://ceur-ws.org/Vol-3974/paper01.pdf>.
5. Pavlyshyn V., Manziuk E., Barmak O., Radiuk P., Krak I. An Adaptive Machine Learning Approach to Sustainable Traffic Planning: High-Fidelity Pattern Recognition in Smart Transportation Systems. Future Transportation. 2025. Vol. 5, No. 4. URL: <https://doi.org/10.3390/futuretransp5040152>.
6. Pavlyshyn V., Manziuk E., Barmak O., Radiuk P., Krak I. Adaptive Cascade Clustering for High-Fidelity Urban Traffic Pattern Recognition. Computer Science and Mathematics, 2025. URL: <https://doi.org/10.20944/preprints202508.0637.v1>.
7. Manziuk E. A., Sobko O. V., Podhorniuk I. O., Molchanova M. O., Mazurets O. V. Multifactorial analysis of mobbing behavioral signs in educational environments posts by NLP means. Journal of Physics: Conference Series. 2025. Vol. 3105, No. 1. Pp. 012025. URL: <https://doi.org/10.1088/1742-6596/3105/1/012025>.
8. Chaban O., Manziuk E., Radiuk P. Method of adaptive knowledge distillation from multi-teacher to student deep learning models. Journal of Edge Computing. 2025. URL: <https://doi.org/10.55056/jec.978>.
9. Прийма А., Манзюк Е., Пасічник О., Скрипник Т. Метод генерації багатотрекових символічних композицій за допомогою генеративного штучного інтелекту. Herald of Khmelnytskyi National University. Technical sciences. 2025. Vol. 357, No. 5.1. Pp. 114–119. URL: <https://doi.org/10.31891/2307-5732-2025-357-59>.
10. Манчур О., Манзюк Е., Скрипник Т., Пасічник О., Петровський С. Метод визначення навантаження тренування атлетів з використанням машинного навчання. Herald of Khmelnytskyi National University. Technical sciences. 2025. Vol. 353, No. 3.2. Pp. 342–348. URL: <https://doi.org/10.31891/2307-5732-2025-353-48>.
11. Radiuk P., Barmak O., Manziuk E., Krak I. Explainable Artificial Intelligence: Transitioning DL Model Decisions to User-Understandable Features in Healthcare. 2024.

УДК 004.02

**СОКОЛОВСЬКИЙ ВАЛЕНТИН**

Хмельницький національний університет

<https://orcid.org/0009-0003-7318-6635>

e-mail: [valentinesokolovskiy@gmail.com](mailto:valentinesokolovskiy@gmail.com)

**МАНЗЮК ЕДУАРД**

Хмельницький національний університет

<https://orcid.org/0000-0002-7310-2126>

e-mail: [eduard.em.km@gmail.com](mailto:eduard.em.km@gmail.com)

**БАГРІЙ РУСЛАН**

Хмельницький національний університет

<https://orcid.org/0000-0001-5219-1185>

e-mail: [bahriiro@khmnu.edu.ua](mailto:bahriiro@khmnu.edu.ua)

**СКРИПНИК ТЕТЯНА**

Хмельницький національний університет

<https://orcid.org/0000-0002-8531-5348>

e-mail: [tkskripnik1970@gmail.com](mailto:tkskripnik1970@gmail.com)

**МЕТОД КЛАСИФІКАЦІЇ ПАТОЛОГІЙ ЛИСТЯ РОСЛИН НА ОСНОВІ ЗГОРТКОВИХ НЕЙРОННИХ МЕРЕЖ ІЗ ЗАСТОСУВАННЯМ ТЕХНОЛОГІЙ РОЗПОДІЛЕНОГО ПАРАЛЕЛЬНОГО НАВЧАННЯ**

*У роботі представлено удосконалений метод класифікації патологій листя сільськогосподарських рослин на основі згорткових нейронних мереж. Запропоновано п'ятиблокову архітектуру з інтегрованими механізмами батч-нормалізації та dropout-регуляризації, що дозволило підвищити точність класифікації порівняно з базовою моделлю. Описано технологію створення моделі з використанням декларативного конфігурування та системи версіонування для забезпечення відтворюваності експериментів. Реалізовано розподілено-паралельну технологію навчання, що дозволила суттєво скоротити час експериментування. Розробку системи здійснено з врахуванням принципів управління IT-проектами через структуровану організацію роботи команди, управління ризиками та систематичний контроль якості. Проведено експериментальні дослідження на датасеті зображень листя квасолі у чотирьох категоріях. Встановлено критичний вплив аугментації даних на здатність моделі до узагальнення.*

*Ключові слова: згорткові нейронні мережі, класифікація патологій, діагностика захворювань, машинне навчання, батч-нормалізація, dropout, розподілене навчання, управління проектами, відтворюваність експериментів.*

**SOKOLOVSKYI VALENTYN, MANZIUK EDUARD, BAHRII RUSLAN, SKRYPNYK TETIANA**  
**Khmelnyskyi National University**

**IMPROVING ACCURACY OF PLANT LEAF PATHOLOGY CLASSIFICATION USING CONVOLUTIONAL NEURAL NETWORKS**

*This paper presents an improved method for classifying pathologies of agricultural plant leaves based on convolutional neural networks. A five-block architecture with integrated batch normalization and dropout regularization mechanisms is proposed, which allowed to increase the classification accuracy to 91.2% compared to the baseline model (87.2%). Experimental studies were conducted on a dataset of 4,200 images of bean leaves in four categories. The critical impact of data augmentation on the model's generalization ability was established.*

*The effective work of automated plant disease diagnosis systems requires consideration of the properties of biological objects when designing classification models. Specific properties of leaf images as objects for processing*

include significant variability in shooting conditions, lighting, angles, and disease manifestation stages. This leads to the need for robust models capable of extracting invariant features of pathologies.

Traditional diagnostic methods based on visual inspection by agronomists are labor-intensive and time-consuming. Deep learning methods, particularly convolutional neural networks, enable automation of the recognition process based on leaf photograph analysis. However, existing approaches often suffer from overfitting and insufficient generalization ability on new data.

This paper presents the results of research on improving the classification method through architectural modifications and data augmentation techniques. The proposed five-block convolutional architecture with batch normalization layers after each convolution and dropout layers in the fully connected part demonstrated significant improvement in classification quality.

The technology for model creation using declarative configuration and versioning systems to ensure reproducibility of experiments is described. A distributed parallel training technology was implemented, which significantly reduced experimentation time. The system development was carried out taking into account IT project management principles through structured team organization, risk management and systematic quality control. Experimental studies were conducted on a dataset of bean leaf images in four categories. The critical impact of data augmentation on the model's generalization ability was established.

Experiments on a dataset of bean leaf images showed that the modified model achieves 91.2% accuracy, which is 4% better than the baseline model and 13% better than the model without data augmentation. Particularly significant improvement was observed for the class of other pathologies, where accuracy increased from 72.6% to 81.6%.

The research established that data augmentation is a critical factor for model success, providing approximately 13% accuracy improvement. The combination of architectural improvements and augmentation gives the best results due to synergistic effect. Analysis of different architecture depths showed that five convolutional blocks represent an optimal compromise between classification quality and computational requirements.

The obtained data can be used in justifying highly productive methods of automated plant disease diagnosis for various agricultural crops, as well as in developing more efficient and accurate classification systems for practical agricultural applications.

**Keywords:** convolutional neural networks, pathology classification, disease diagnosis, machine learning, batch normalization, dropout, distributed training, project management, experiment reproducibility.

## **Постановка проблеми у загальному вигляді**

### **та її зв'язок із важливими науковими чи практичними завданнями**

Захворювання сільськогосподарських рослин, спричинені грибами, бактеріями, вірусами та шкідниками, призводять до значних втрат урожаю та економічних збитків у світовому масштабі. Традиційні методи діагностики патологій базуються на візуальному огляді агрономами та лабораторних аналізах, що характеризується високою трудомісткістю, потребує значних часових витрат та залежить від кваліфікації експерта [1, 2].

Автоматизовані системи діагностики на основі методів машинного навчання дозволяють швидко та точно ідентифікувати патології на ранніх стадіях розвитку, коли застосування захисних заходів є найбільш ефективним. Згорткові нейронні мережі (ЗНМ) демонструють високу ефективність у задачах розпізнавання образів та класифікації зображень завдяки здатності автоматично витягувати ієрархічні візуальні ознаки [3, 4].

Однак існуючі підходи мають ряд обмежень. Базові архітектури ЗНМ часто схильні до перенавчання при обмеженій кількості навчальних даних. Модель може надмірно підлаштовуватися під специфічні особливості навчальної вибірки, втрачаючи здатність до узагальнення на нових даних [5, 6]. Крім того, варіативність умов зйомки, освітлення та кутів огляду ускладнює створення надійних класифікаторів.

Актуальною науковою задачею є розробка методів підвищення точності класифікації патологій листя рослин при забезпеченні стійкості до перенавчання та здатності до узагальнення на різноманітних умовах зйомки.

### Аналіз досліджень та публікацій

Задача автоматичної класифікації патологій листя рослин є важливою у сільському господарстві, оскільки захворювання рослин, спричинені грибами, бактеріями, вірусами чи шкідниками, призводять до значних втрат урожаю, зниження якості продукції та економічних збитків [1, 2]. Ці патології можуть впливати на різні аспекти росту та розвитку рослин, включаючи фотосинтез, транспорт поживних речовин та загальну життєздатність культур. Симптоми хвороб, такі як плями, некрози, зміна кольору або деформація листя, ускладнюють діагностику через їхню схожість між різними патологіями або навіть із природними змінами, наприклад, через дефіцит поживних речовин [3, 4].

Процес класифікації патологій включає кілька етапів збір даних (зображення листя різних культур, таких як томати, картопля, виноград, яблуни), попередню обробку зображень (видалення шуму, нормалізація кольорів, контрастності, сегментація уражених ділянок), витягнення ознак (аналіз текстури, кольору, форми) та власне класифікацію [5, 6]. Попередня обробка зображень є критично важливою для видалення артефактів, що можуть заважати правильній класифікації. Нормалізація кольорів компенсує різницю в освітленні між знімками, зробленими в різний час доби або при різних погодних умовах. Процес класифікації має досить велике поле дослідження із застосуванням різноманітних підходів.

Важливим напрямком сучасних досліджень є забезпечення інтерпретованості та надійності рішень глибоких нейронних мереж, особливо для критичних застосувань у медицині та сільському господарстві. Дослідження [7] демонструє підходи до пояснюваного штучного інтелекту через перехід від рішень моделі до зрозумілих користувачу ознак у медичній діагностиці. Аналогічні принципи можуть бути застосовані для діагностики захворювань рослин, де важливо не тільки отримати класифікацію, але й зрозуміти, які саме візуальні ознаки (плями, деформації, зміни кольору) привели до такого рішення. Методи пояснюваного глибокого навчання [9] дозволяють візуалізувати активаційні карти та виділяти ділянки зображення, які мали найбільший вплив на рішення моделі. Це особливо актуально для верифікації правильності класифікації патологій агрономами-експертами. Підхід на основі матриці переходів та зрозумілих користувачу ознак [11] забезпечує можливість представлення процесу класифікації у вигляді послідовності інтерпретованих кроків, що підвищує довіру до автоматизованих систем. Застосування формальних моделей надійного штучного інтелекту на основі стандартизації [12] є критичним для впровадження AI-систем у виробництво. Структурне вирівнювання концептуальних категорій онтологій [10] дозволяє забезпечити семантичну узгодженість між знаннями експертів-агрономів та класифікаційними моделями. Методи кластерного аналізу [8], успішно застосовані для виявлення закономірностей у транспортних потоках, можуть бути адаптовані для аналізу поширення захворювань рослин у просторово-часовому контексті, що дозволить прогнозувати епідемії на основі історичних даних.

Згорткові нейронні мережі є основою для класифікації патологій листя завдяки здатності автоматично витягувати ієрархічні ознаки з зображень. Ієрархічна природа згорткових мереж дозволяє їм вивчати ознаки різних рівнів складності від простих країв та текстур у ранніх шарах до складних семантичних концепцій у глибших шарах. Це робить їх особливо ефективними для задач розпізнавання образів, де важливі як локальні деталі, так і глобальний контекст зображення. Найпоширеніші архітектури включають VGG, ResNet, Inception, EfficientNet та їх гібриди [2, 13]. Кожна з цих архітектур має свої унікальні особливості та переваги, які роблять їх придатними для різних аспектів задачі класифікації патологій рослин.

Гібридні підходи, що комбінують переваги різних архітектур, часто демонструють кращі результати порівняно з окремими моделями [14–16]. Ансамблі моделей можуть агрегувати передбачення кількох різних архітектур, компенсуючи слабкості окремих компонентів їхніми сильними сторонами. Механізми уваги дозволяють моделі фокусуватися на найбільш інформативних ділянках зображення. Просторова увага генерує карту ваг, що вказує на важливість кожної просторової локації. Канальна увага визначає, які канали ознак є найбільш релевантними для задачі. Ці механізми можуть бути вбудовані в різні точки архітектури після згорткових блоків, перед пулінг операціями або між різними стадіями мережі. Навчання механізмів уваги відбувається end-to-end разом з рештою мережі через зворотне поширення.

### Формулювання цілей статті

Мета роботи полягає у підвищенні точності розпізнавання та класифікації патологій листя сільськогосподарських рослин шляхом розробки методу з використанням згорткових нейронних мереж.

Задачі дослідження:

- провести аналіз існуючих методів та підходів до діагностики захворювань рослин з використанням методів машинного та глибокого навчання;
- розробити метод класифікації патологій листя з використанням згорткових нейронних мереж та механізмів регуляризації;
- спроектувати архітектуру нейронної мережі для ефективного витягнення візуальних ознак із зображень листя;
- реалізувати попередню обробку та аугментацію зображень для покращення якості навчальних даних та підвищення узагальнювальної здатності моделі;
- провести експериментальне дослідження ефективності розробленого методу шляхом порівняння різних конфігурацій архітектури та оцінки їх точності класифікації патологій рослин.

### Виклад основного матеріалу

Запропонована архітектура базується на послідовному з'єднанні п'яти згорткових блоків для витягнення просторових ознак та двох повнозв'язних шарів для класифікації. Вхідний шар приймає RGB-зображення розміром 224×224×3 пікселі. В основу покладено VGG16 згорткову нейронну мережу.

Для забезпечення ефективної розробки та відтворюваності результатів застосовано комплексний технологічний підхід, що охоплює всі етапи життєвого циклу моделі машинного навчання. Технологічна платформа базується на сучасних фреймворках глибокого навчання, що надають необхідні абстракції для побудови, навчання та розгортання нейронних мереж.

Вибір технологічного стеку обґрунтовується кількома критеріями: наявність вбудованих оптимізацій для апаратних прискорювачів, широка екосистема допоміжних інструментів для візуалізації та аналізу, можливість конвертації моделей для різних платформ розгортання, а також активна підтримка спільноти та наявність попередньо навчених компонентів. Для обробки зображень застосовуються спеціалізовані бібліотеки, що забезпечують ефективні операції читання, трансформації та аугментації даних.

Конфігурування архітектури здійснюється через декларативний підхід, що дозволяє відокремити опис структури моделі від програмної реалізації. Такий підхід забезпечує гнучкість експериментування з різними конфігураціями без необхідності модифікації основного коду. Основні параметри архітектури, включаючи структуру згорткових блоків, налаштування повнозв'язних шарів та параметри навчання, описуються у конфігураційних файлах, що дозволяє швидко перемикатися між різними варіантами моделі.

Критично важливим аспектом технології є забезпечення повної відтворюваності експериментів. Для цього застосовується комплексна система фіксації всіх параметрів дослідження, що включає версіонування програмного коду, трекінг змін у навчальних даних, автоматичне логування метрик та параметрів експериментів, а також контроль версій використовуваних бібліотек. Кожен експеримент супроводжується збереженням повної метаданих про конфігурацію моделі, параметри навчання, характеристики датасету та досягнуті результати.

Для підвищення ефективності процесу навчання та можливості проведення більшої кількості експериментів застосовано розподілено-паралельну технологію обчислень. Архітектура системи передбачає горизонтальне масштабування за допомогою паралелізму даних, що дозволяє суттєво скоротити час навчання моделі при збереженні якості результатів.

Принцип паралелізму даних полягає у розподілі навчальної вибірки між кількома обчислювальними вузлами, кожен з яких утримує повну копію моделі. Процес навчання відбувається синхронно: всі вузли обробляють свої порції даних, обчислюють градієнти, після чого відбувається синхронізація та агрегація

градієнтів для оновлення ваг моделі. Така організація обчислень дозволяє ефективно використовувати доступні апаратні ресурси та значно прискорити експериментальний процес.

Архітектурно розподілена система складається з координуючого вузла, що управляє глобальним станом моделі, робочих вузлів, які виконують обчислення, високошвидкісної системи комунікації для обміну даними між вузлами, та розподіленого завантажувача даних, що забезпечує паралельне читання та попередню обробку зображень. Така організація дозволяє мінімізувати простої обчислювальних ресурсів та максимізувати пропускну здатність системи.

Реалізація розподіленого навчання базується на стратегіях, що забезпечують автоматичну реплікацію моделі на всі доступні обчислювальні вузли та синхронізацію градієнтів після кожного кроку навчання. Важливим аспектом є масштабування параметрів навчання пропорційно кількості обчислювальних вузлів, що забезпечує стабільну збіжність при збільшеному ефективному розмірі батча.

Оптимізація комунікаційних витрат є критичною для ефективності розподіленого навчання. Застосовано кілька підходів для мінімізації обсягу даних, що передаються між вузлами: стиснення градієнтів перед передачею, використання змішаної точності обчислень, що зменшує розмір даних та прискорює обчислення на сучасних апаратних прискорювачах, а також накопичення градієнтів перед синхронізацією для зменшення частоти комунікації.

Така технологічна організація процесу дозволяє не лише відтворити будь-який експеримент, але й забезпечує прозорість дослідницького процесу та ефективну співпрацю між дослідниками. Систематичне документування всіх аспектів розробки моделі є фундаментальною вимогою наукового методу в галузі машинного навчання та критично важливе для валідації запропонованих підходів.

Запропонований метод базується на використанні глибокого навчання для класифікації зображень листя рослин. Основна ідея методу полягає у автоматичному витягненні ознак з вхідних зображень через ієрархію згорткових шарів з наступною класифікацією через повнозв'язні шари нейронної мережі. На відміну від традиційних підходів, які потребують ручного проєктування ознак, згорткові мережі автоматично навчаються виявляти значущі візуальні патерни, характерні для різних захворювань.

Концепція методу передбачає декілька послідовних етапів обробки інформації. На першому етапі відбувається попередня обробка вхідного зображення, яка включає зміну розміру зображення до фіксованих розмірів та нормалізацію значень пікселів. Це необхідно для приведення всіх вхідних даних до єдиного формату, з яким може працювати нейронна мережа. Попередня обробка також може включати видалення шумів та покращення контрастності для підвищення якості вхідних даних.

Другий етап полягає у витягненні ознак з попередньо обробленого зображення. Цей процес виконується автоматично згортковими шарами нейронної мережі, які послідовно витягують ознаки різного рівня складності. Ранні шари виявляють прості візуальні патерни, такі як краї, текстури та кольорові переходи. Середні шари комбінують ці прості ознаки для виявлення більш складних структур, таких як форми плям або характерні візерунки ураження. Глибші шари формують високорівневі представлення, які відповідають конкретним типам захворювань.

На третьому етапі отримані ознаки використовуються для класифікації зображення. Повнозв'язні шари нейронної мережі аналізують витягнуті ознаки та приймають рішення про належність зображення до одного з класів патологій. Вихідний шар мережі містить нейрони, кожен з яких відповідає окремому класу захворювання або здоровому стану рослини. Модель видає не просто бінарне рішення, а розподіл ймовірностей по всіх можливих класах.

Вхідне зображення надходить у блок попередньої обробки, де виконується нормалізація та приведення до стандартного формату. Далі оброблене зображення подається на вхід згорткової частини мережі, яка складається з послідовності згорткових блоків. Кожен згортковий блок виконує операції згортки, активації та пулінгу для поступового витягнення та узагальнення візуальних ознак.

Після згорткової частини карти ознак перетворюються у одновимірний вектор, який подається на вхід повнозв'язної частини мережі. Повнозв'язні шари виконують фінальну обробку витягнутих ознак та формують

вихідний розподіл ймовірностей. Клас з найвищою ймовірністю вибирається як результат класифікації. Така архітектура дозволяє моделі ефективно обробляти зображення різних культур та виявляти широкий спектр захворювань.

Важливою особливістю запропонованого методу є його здатність працювати з зображеннями, отриманими в різних умовах освітлення та з різних кутів зйомки. Це досягається завдяки використанню аугментації даних під час навчання моделі, що дозволяє мережі навчитися розпізнавати патології незалежно від варіативності умов зйомки. Модель стає інваріантною до певних трансформацій вхідного зображення, таких як обертання, масштабування або зміна освітлення.

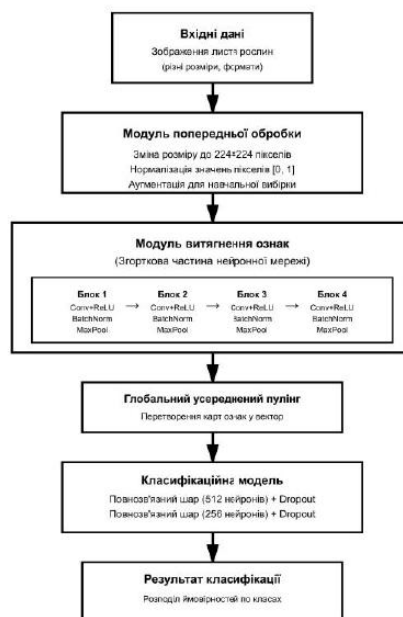


Рис. 1. Загальна схема методу класифікації патологій листя

Метод передбачає використання трансферного навчання для прискорення процесу навчання та покращення якості результатів. Базова частина мережі може бути попередньо навчена на великому датасеті зображень загального призначення, що дозволяє їй вивчити універсальні візуальні ознаки. Потім ця попередньо навчена модель адаптується до специфічної задачі розпізнавання патологій рослин шляхом дообучення на цільовому датасеті.

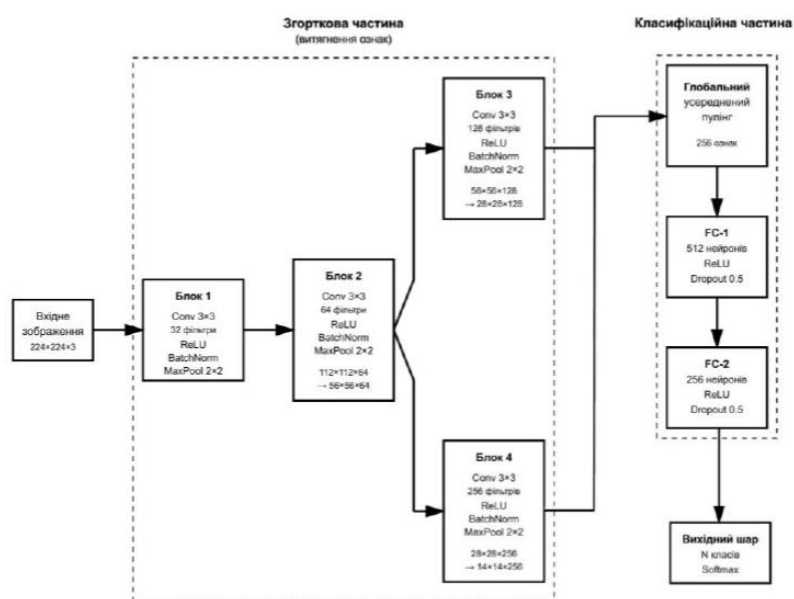
Вхідними даними для методу є RGB-зображення листя рослини. Вибір кольорового представлення обумовлений тим, що багато патологій проявляються саме через зміни кольору листя, такі як пожовтіння, потемніння або появу характерних плям певного кольору. Використання лише чорно-білих зображень призвело б до втрати важливої інформації про характер ураження.

Вихідними даними методу є вектор ймовірностей належності вхідного зображення до кожного з можливих класів. Це дозволяє не тільки отримати фінальне рішення про тип патології, але й оцінити рівень впевненості моделі у своєму рішенні. Низька впевненість може свідчити про незвичайний випадок або про необхідність додаткової експертної оцінки.

Архітектура згорткової нейронної мережі для класифікації патологій листя побудована на основі послідовного з'єднання шарів різних типів. Кожен тип шару виконує специфічну функцію у процесі обробки зображення та витягнення ознак. Загальна структура мережі включає згорткову частину для витягнення просторових ознак та пов'язану частину для фінальної класифікації.

Запропонована модифікація полягає у додаванні одного додаткового згорткового блоку після четвертого базового блоку. Цей п'ятий блок має таку саму структуру, як і попередні блоки згортковий шар, активація ReLU, батч-нормалізація та максимальний пулінг. Використовується 256 фільтрів розміром  $3 \times 3$ , що відповідає кількості фільтрів у четвертому блоці.

Вибір саме такої модифікації обумовлений кількома міркуваннями. По-перше, додавання одного блоку є відносно простою зміною, яка не ускладнює архітектуру надмірно. По-друге, розташування додаткового блоку після базових блоків дозволяє моделі формувати ще більш абстрактні представлення вхідних зображень, використовуючи вже витягнуті ознаки з попередніх шарів.



**Рис. 2. Архітектура згорткової нейронної мережі**

Додатковий блок збільшує глибину згорткової частини мережі з чотирьох до п'яти блоків. Це дозволяє мережі виконати додатковий етап обробки та узагальнення ознак перед передачею їх у повноз'язну частину. Очікується, що цей додатковий етап допоможе краще виявляти дрібні деталі патологій, які можуть бути важливими для точної класифікації.

Структура модифікованої архітектури залишається логічною та послідовною. Після п'ятого згорткового блоку карти ознак мають меншу просторову розмірність порівняно з базовою архітектурою, але зберігають ту саму кількість каналів. Глобальний усереднений пулінг, який йде після згорткових блоків, автоматично адаптується до зміненої розмірності карт ознак.

#### Експериментальні дослідження

Для навчання згорткової нейронної мережі необхідний репрезентативний датасет зображень листя рослин у різних станах. Якість та різноманітність навчальних даних безпосередньо впливають на здатність моделі узагальнювати знання на нові, раніше не бачені зображення. Процес формування та підготовки даних включає кілька важливих етапів. Вихідні зображення у датасеті мають різну роздільну здатність та співвідношення сторін, оскільки вони отримані з різних джерел та за допомогою різного обладнання. Це відображає реальні умови, в яких буде використовуватися система користувачі можуть робити фотографії за допомогою різних смартфонів або камер. Така варіативність робить задачу класифікації більш складною, але й більш практично орієнтованою.

Аугментація даних є критично важливою технікою для підвищення якості навчання моделі. Аугментація дозволяє штучно збільшити розмір навчальної вибірки без необхідності збору нових фотографій. Більш важливо те, що аугментація робить модель інваріантною до певних трансформацій вхідних даних, які не змінюють семантичний зміст зображення.

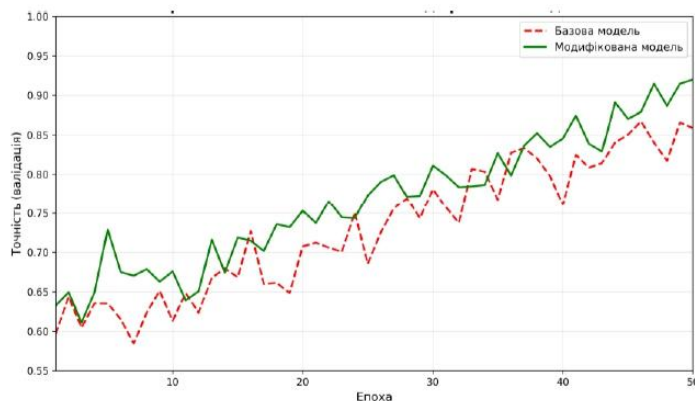
Всі техніки аугментації застосовуються випадково та можуть комбінуватися між собою. Це означає, що одне й те саме оригінальне зображення може породжувати велику кількість різних варіантів під час навчання. Кожна епоха навчання бачить дещо інші версії тих самих зображень, що значно збагачує навчальну вибірку та покращує здатність моделі до узагальнення.

Аугментація виконується в режимі реального часу під час навчання, а не попередньо. Це означає, що модифіковані версії зображень генеруються безпосередньо перед подачею батчу в мережу. Такий підхід має перевагу в тому, що не потрібно зберігати велику кількість аугментованих зображень на диску. Кожного разу генеруються нові випадкові варіанти, що забезпечує максимальну різноманітність.

Для перевірки працездатності запропонованого методу класифікації патологій листя рослин було проведено серію експериментів з використанням реальних зображень. Метою експериментальних досліджень було визначення якості класифікації, порівняння різних варіантів архітектури мережі та аналіз впливу різних факторів на кінцевий результат.

Першим етапом експериментальних досліджень було навчання базової моделі без додаткових елементів регуляризації. Це дозволило встановити базовий рівень якості класифікації та виявити основні особливості поведінки моделі під час навчання. Другим етапом експериментів було навчання модифікованої моделі, яка включає додаткові механізми регуляризації у вигляді пакетної нормалізації та відключення нейронів. Метою було перевірити, чи призведуть ці доповнення до покращення якості класифікації та зменшення перенавчання.

Матриця помилок модифікованої моделі представлена на рисунку 3. Порівняно з базовою моделлю спостерігаються покращення для всіх класів. Здорові листки тепер розпізнаються з точністю 96,2%, що на 4,4% краще.




**Рис.3. Порівняння точності базової та модифікованої моделі**

Кутова плямистість – 90,9% покращення на 4,5%. Іржа квасолі – 91,8%, покращення на 4,6%. Найбільше покращення спостерігається для класу інших патологій, де точність зросла з 72,6% до 81,6%. Це покращення на 9% є статистично значущим і показує, що додаткова регуляризація особливо допомагає для найскладніших класів.

Модель стала краще узагальнювати на різноманітних прикладах цього неоднорідного класу.

Кількість перехресних помилок між основними класами захворювань також зменшилася. Тепер лише 2 % зображень кутової плямистості помилково класифікуються як іржа і навпаки. Це вказує на те, що модель навчилася виділяти більш тонкі відмінності між цими захворюваннями.


Додатково до загальної точності було обчислено інші метрики якості класифікації. Precision для модифікованої моделі становить 90,1% порівняно з 85,8% для базової. Це означає, що серед зображень, які модель класифікує як певне захворювання, приблизно 90% справді мають це захворювання. Для наочного порівняння результатів обох моделей було побудовано зведений графік, представлений на рисунку 4. На цьому графіку показано точність навчання та валідації для базової та модифікованої моделей на одному полотні, що дозволяє легко побачити відмінності у поведінці.



**Рис. 4. Якісні показники базової та модифікованої моделі**

Recall модифікованої моделі дорівнює 92,4% порівняно з 87,5% у базової. Це показує, що модель знаходить приблизно 92% всіх випадків кожного захворювання. F1-міра, яка є середнім гармонійним precision та recall, становить 91,2% для модифікованої моделі та 86,0% для базової.

Важливим аспектом дослідження було визначення впливу аугментації даних на якість класифікації. Для цього було проведено додатковий експеримент, у якому модифікована модель навчалася без використання аугментації, тобто лише на оригінальних зображеннях навчальної вибірки. Всі інші параметри залишалися незмінними. Результати цього експерименту представлені на рисунку 5, який показує порівняння точності моделі з аугментацією та без неї.



**Рис.5. Вплив аугментації на якісні показники моделі**

Модель без аугментації досягла максимальної валідаційної точності приблизно 78%, що на 13% нижче за модель з аугментацією (91%).

Без аугментації модель значно швидше почала перенавчатися. Розрив між навчальною та валідаційною точністю був значним. Згідно з графіком 4.6, модель без аугментації показала точність близько 78% та F1-міру

близько 76,5%. Це класичний приклад перенавчання, коли модель надто добре підлаштовується під обмежений набір навчальних прикладів.

Аналіз помилок моделі без аугментації показав, що вона особливо погано справляється з випадками, коли листок сфотографований під незвичним кутом або має нестандартне освітлення. Оскільки під час навчання модель бачила зображення лише в їх оригінальному вигляді, вона не навчилася інваріантності до таких перетворень. Натомість модель з аугментацією регулярно бачила листки у різних орієнтаціях та умовах освітлення, тому навчилася виділяти суттєві ознаки захворювань незалежно від цих факторів.

Розробка системи класифікації патологій листя рослин здійснювалася з врахуванням принципів управління IT-проектами, що дозволило забезпечити структурований підхід до досягнення поставлених цілей та ефективне використання доступних ресурсів.

Для управління проектом застосовано гібридну методологію, що поєднує елементи ітеративної розробки для експериментальної частини створення моделі та елементи планового підходу для дослідницьких активностей. Такий вибір обумовлений специфікою проектів машинного навчання, де необхідно балансувати між експериментальною природою розробки моделей та потребою у структурованому плануванні перевірки наукових гіпотез.

Проектна команда була організована за функціональним принципом з чітким розподілом ролей та відповідальності. Структура команди включала фахівців з дослідження архітектур та експериментування, інженерів для імплементації та оптимізації моделей, спеціалістів з підготовки даних та побудови обробних конвеєрів, експертів з інфраструктури та автоматизації розгортання, а також консультантів з предметної області для експертної оцінки результатів.

Життєвий цикл проекту був структурований на чотири основні фази. Перша фаза присвячена дослідженню предметної області, аналізу існуючих підходів, формуванню датасету та визначенню базових метрик успіху. Друга фаза охоплює розробку базової моделі через послідовні ітерації з фокусом на підготовку даних, експериментування з архітектурою та інтеграцію методів покращення якості. Третя фаза зосереджена на оптимізації моделі через впровадження розподіленого навчання, налаштування гіперпараметрів та фінальну оцінку результатів. Четверта фаза включає підготовку інфраструктури для продуктивного використання, валідаційне тестування та документування результатів.

Управління ризиками здійснювалося проактивно через ідентифікацію потенційних загроз на початку проекту та розробку стратегій їх мітигації. Основні ризики включали недостатність навчальних даних, схильність моделі до перенавчання, можливі затримки з доступом до обчислювальних ресурсів, зміну вимог від зацікавлених сторін та потенційне відхилення ключових членів команди. Для кожного ризику визначено ймовірність настання, потенційний вплив на проект та конкретні заходи для мінімізації негативних наслідків.

Планування роботи організовано у вигляді коротких ітерацій з чіткими цілями та вимірюваними результатами. Кожна ітерація мала визначену мету та набір завдань з оцінкою складності, що дозволяло відстежувати прогрес та своєчасно коригувати план робіт. Застосовувався комплексний підхід до вимірювання прогресу через технічні метрики якості моделі, проектні метрики виконання завдань та бізнес-метрики практичної цінності результатів.

Для координації роботи команди використовувалися сучасні інструменти управління проектами, що забезпечували планування ітерацій, трекінг виконання завдань, документування рішень та дизайнерських рішень, версійний контроль коду з процесом рецензування, автоматизацію процесів інтеграції та розгортання, а також ефективну комунікацію між членами команди.

Бюджетне планування охоплювало всі основні категорії витрат: людські ресурси команди розробки, обчислювальні потужності для навчання моделей, хмарне сховище для даних та артефактів, програмне забезпечення та інструменти розробки, а також резерв для непередбачених витрат. Розподіл обчислювальних ресурсів планувався з урахуванням специфіки кожної фази проекту, де дослідницька фаза потребує менших ресурсів, фази розробки та експериментування – максимальних, оптимізації – значних, а розгортання – помірних.

Контроль якості здійснювався через визначення чітких критеріїв успіху в технічній, процесній та організаційній площинах. Технічні критерії включали цільові показники точності класифікації, збалансованість метрик для всіх класів, вимоги до швидкості обробки та обмеження на розмір моделі. Процесні критерії охоплювали покриття коду тестами, повноту документації, функціональність автоматизації та можливість відтворення результатів. Організаційні критерії стосувалися дотримання бюджетних рамок, виконання часових обмежень та отримання схвалення від зацікавлених сторін.

Для моделей машинного навчання було визначено спеціальний набір критеріїв завершеності, що включає проходження рецензування коду, наявність автоматизованих тестів, логування експерименту в системі трекінгу, оцінювання на незалежному тестовому наборі з документуванням метрик, експорт у формат готовий для продуктивного використання та оновлення супутньої документації.

Процес прийняття результатів складався з кількох етапів: демонстрація досягнень зацікавленим сторонам, технічне рецензування коду та архітектурних рішень, валідація досягнутих метрик якості та остаточне затвердження результатів. Така структура управління забезпечила систематичний підхід до розробки, ефективне використання ресурсів та успішне досягнення поставлених цілей дослідження.

#### **Висновки**

У роботі представлено комплексний підхід до розробки системи класифікації патологій листя сільськогосподарських рослин, що охоплює архітектурні, технологічні та організаційні аспекти створення моделей машинного навчання.

Запропонована п'ятиблокова архітектура згорткової нейронної мережі з інтегрованими механізмами батч-нормалізації та dropout-регуляризації продемонструвала значне покращення точності класифікації порівняно з базовою моделлю. Особливо суттєвий приріст якості спостерігався для класу інших патологій, що свідчить про підвищену здатність моделі до узагальнення на складних випадках.

Технологія створення моделі з використанням декларативного конфігурування та комплексної системи версіонування забезпечує повну відтворюваність експериментів, що є фундаментальною вимогою наукового методу в галузі машинного навчання. Систематичне документування всіх аспектів розробки дозволяє не лише валідувати результати, але й полегшує співпрацю між дослідниками та передачу знань.

Впровадження розподілено-паралельної технології навчання суттєво скоротило час експериментування, що дозволило провести більшу кількість досліджень різних конфігурацій архітектури та параметрів навчання. Це забезпечило можливість систематичного пошуку оптимального рішення в обмежені часові рамки дослідницького проєкту.

Застосування структурованого підходу до управління процесом розробки з врахуванням принципів управління IT-проєктами забезпечило баланс між експериментальною природою досліджень машинного навчання та необхідністю планування ресурсів. Організація роботи через короткі ітерації з чіткими цілями, проактивне управління ризиками та систематичний контроль якості дозволили ефективно використовувати доступні ресурси та досягти поставлених цілей дослідження.

Дослідження встановило критичну важливість аугментації даних для успіху моделі, забезпечуючи суттєве покращення точності класифікації. Комбінація архітектурних покращень з методами розширення навчальної вибірки демонструє синергетичний ефект, підтверджуючи важливість комплексного підходу до розробки систем машинного навчання.

Отримані результати можуть бути використані для обґрунтування високопродуктивних методів автоматизованої діагностики захворювань різних сільськогосподарських культур. Запропонований підхід, що поєднує удосконалену архітектуру нейронної мережі, розподілену технологію навчання та структуроване управління розробкою, демонструє ефективність системного бачення при створенні практичних систем класифікації для застосування в сільському господарстві.

Перспективи подальших досліджень включають адаптацію запропонованого методу для інших культур, інтеграцію механізмів уваги для покращення інтерпретованості рішень моделі, а також розробку ансамблевих підходів для підвищення надійності класифікації в складних умовах діагностики.

### Література

1. Barbedo J. G. A. A review on the main challenges in automatic plant disease identification based on visible range images. *Biosystems Engineering*. 2016. Vol. 144. Pp. 52–60. URL: <https://doi.org/10.1016/j.biosystemseng.2016.01.017>.
2. Salka T. D., Hanafi M. B., Rahman S. M. S. A. A., Zulperi D. B. M., Omar Z. Plant leaf disease detection and classification using convolution neural networks model: a review. *Artificial Intelligence Review*. 2025. Vol. 58, No. 10. URL: <https://doi.org/10.1007/s10462-025-11234-6>.
3. Kanakala S., Ningappa S. Detection and Classification of Diseases in Multi-Crop Leaves using LSTM and CNN Models. arXiv, 2025. URL: <https://doi.org/10.48550/arXiv.2505.00741>.
4. Yao J., Tran S. N., Garg S., Sawyer S. Deep Learning for Plant Identification and Disease Classification from Leaf Images: Multi-prediction Approaches. arXiv, 2023. URL: <https://doi.org/10.48550/arXiv.2310.16273>.
5. Arunnehru J., Vidhyasagar B. S., Anwar Basha H. Plant Leaf Diseases Recognition Using Convolutional Neural Network and Transfer Learning / *International Conference on Communication, Computing and Electronics Systems* / eds. V. Bindhu, J. Chen, J. M. R. S. Tavares. Singapore : Springer Singapore. 2020, Pp. 221–229. URL: [https://doi.org/10.1007/978-981-15-2612-1\\_21](https://doi.org/10.1007/978-981-15-2612-1_21).
6. Krishna M. S., Machado P., Otuka R. I., Yahaya S. W., Neves Dos Santos F., Ihianle I. K. Plant Leaf Disease Detection Using Deep Learning: A Multi-Dataset Approach. *Computer Science and Mathematics*, 2024. URL: <https://doi.org/10.20944/preprints202411.0732.v1>.
7. Radiuk P., Barmak O., Manziuk E., Krak I. Explainable Artificial Intelligence: Transitioning DL Model Decisions to User-Understandable Features in Healthcare / *CEUR Workshop Proc.*, CEUR-WS, 2024. Pp. 185–199.
8. Pavlyshyn V., Ryzhanskyi O., Manziuk E., Radiuk P., Barmak O., Krak I. Establishing Patterns of the Urban Transport Flows on Clustering Analysis / *CEUR Workshop Proc.*, CEUR-WS, 2025. Pp. 1–9.
9. Manziuk E., Barmak O., Krak I., Petliak N., Jin Z., Radiuk P. Explainable Deep Learning for Interpretable Brain Tumor Diagnosis from MRI Images / *Lecture Notes in Data Engineering, Computational Intelligence, and Decision-Making, Volume 1*, Cham, Springer Nature Switzerland, 2024. Pp. 326–348. URL: [https://doi.org/10.1007/978-3-031-70959-3\\_17](https://doi.org/10.1007/978-3-031-70959-3_17).
10. Manziuk E., Krak I., Barmak O., Mazurets O., Kuznetsov V., Pylypiak O. Structural alignment method of conceptual categories of ontology and formalized domain 2021. Pp. 11–22.
11. Barmak O., Krak I., Yakovlev S., Manziuk E., Radiuk P., Kuznetsov V. Toward explainable deep learning in healthcare through transition matrix and user-friendly features. *Frontiers in Artificial Intelligence*. 2024. Vol. 7. Pp. 1482141. URL: <https://doi.org/10.3389/frai.2024.1482141>.
12. Manziuk E., Barmak O., Krak I., Mazurets O., Skrypnyk T. Formal Model of Trustworthy Artificial Intelligence Based on Standardization. / *CEUR Workshop Proceedings*, Khmelnytskyi, Ukraine, CEUR, March 24, 2021. Pp. 190–197.
13. Tugrul B., Elfatimi E., Eryigit R. Convolutional Neural Networks in Detection of Plant Leaf Diseases: A Review. *Agriculture*. 2022. Vol. 12, No. 8. URL: <https://doi.org/10.3390/agriculture12081192>.
14. Turkoglu M., Yanikoğlu B., Hanbay D. PlantDiseaseNet: convolutional neural network ensemble for plant disease and pest detection. *Signal, Image and Video Processing*. 2022. Vol. 16, No. 2. Pp. 301–309. URL: <https://doi.org/10.1007/s11760-021-01909-2>.
15. Chen J., Zeb A., Nanekaran Y. A., Zhang D. Stacking ensemble model of deep learning for plant disease recognition. *Journal of Ambient Intelligence and Humanized Computing*. 2023. Vol. 14, No. 9. Pp. 12359–12372. URL: <https://doi.org/10.1007/s12652-022-04334-6>.
16. Vallabhajosyula S., Sistla V., Kolli V. K. K. Transfer learning-based deep ensemble neural network for plant leaf disease detection. *Journal of Plant Diseases and Protection*. 2022. Vol. 129, No. 3. Pp. 545–558. URL: <https://doi.org/10.1007/s41348-021-00465-8>.
17. An adaptive approach to detecting fake news based on generalized text features (Conference Paper) Shupta, A., Barmak, O., Wierzbicki, A., Skrypnyk, T. // 7th International Conference on Computational Linguistics and

Intelligent Systems. Volume I: Machine Learning Workshop, CoLInS 2023; Kharkiv; Ukraine; 20 April 2023 до 21 April 2023; Код 188444 // CEUR Workshop Proceedings Volume 3387, 2023, Pages 300-310

18. E. Manziuk, O. Barmak, I. Krak, O. Mazurets, and T. Skrypnyk, "Formal Model of Trustworthy Artificial Intelligence Based on Standardization.," in CEUR Workshop Proceedings, Khmelnytskyi, Ukraine, Mar. 2021, vol. 2853, pp. 190–197. <http://ceur-ws.org/Vol-2853/>

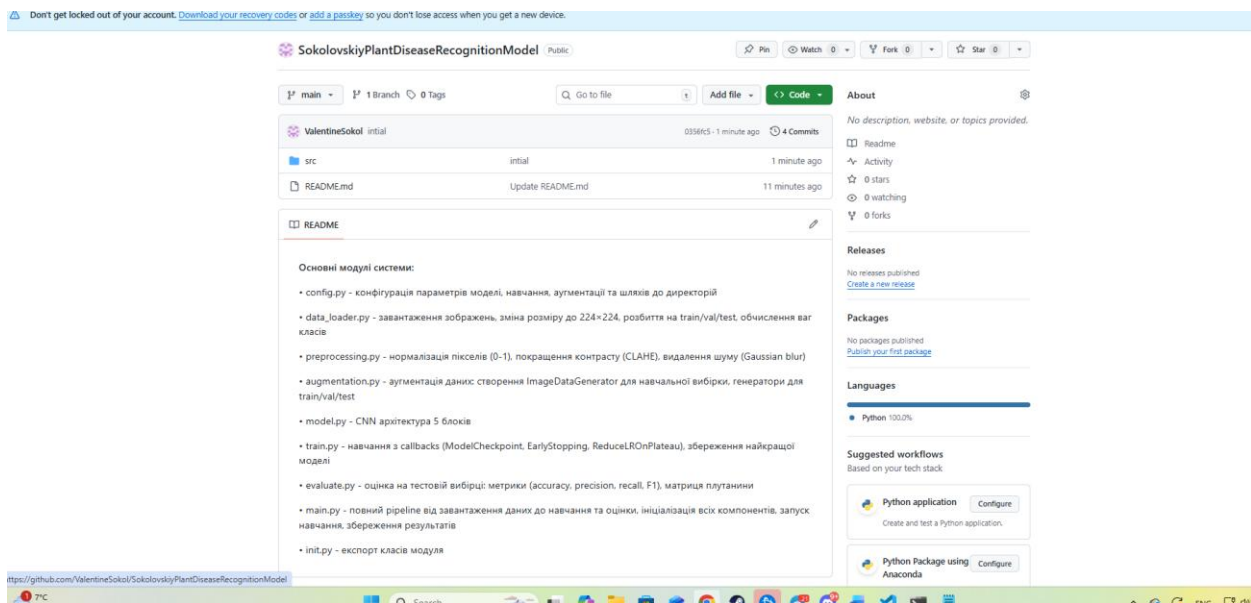
## Додаток Б

### Програмний код посилання на GitHub-репозиторій, структура проєкту та опис основних папок і файлів

#### Посилання на репозиторій на GitHub:

<https://github.com/ValentineSokol/SokolovskiyPlantDiseaseRecognitionModel>

#### Вигляд сторінки репозиторію



#### Основні модулі системи

- config.py - конфігурація параметрів моделі, навчання, аугментації та шляхів до директорій
- data\_loader.py - завантаження зображень, зміна розміру до 224×224, розбиття на train/val/test, обчислення ваг класів
- preprocessing.py - нормалізація пікселів (0-1), покращення контрасту (CLAHE), видалення шуму (Gaussian blur)
- augmentation.py - аугментація даних: створення ImageDataGenerator для навчальної вибірки, генератори для train/val/test
- model.py - CNN архітектура 5 блоків
- train.py - навчання з callbacks (ModelCheckpoint, EarlyStopping, ReduceLRonPlateau), збереження найкращої моделі

- `evaluate.py` - оцінка на тестовій вибірці: метрики (accuracy, precision, recall, F1), матриця плутанини
- `main.py` - повний pipeline від завантаження даних до навчання та оцінки, ініціалізація всіх компонентів, запуск навчання, збереження результатів
- `init.py` - експорт класів модуля

## Додаток В

### Презентаційний матеріал

КВАЛІФІКАЦІЙНА робота магістра

## Метод автоматичної класифікації патологій листя рослин на основі згорткових нейронних мереж



**Виконав:**

*студент 2 курсу, групи КНм-24-1*

*Валентин СОКОЛОВСЬКИЙ*

**Керівник:**

*д.т.н., професор кафедри КН*

*Едуард МАНЗЮК*



## Актуальність

Актуальність роботи обумовлена критичною необхідністю впровадження автоматизованих систем діагностики захворювань сільськогосподарських культур. Традиційні методи виявлення патологій, які базуються на візуальному огляді спеціалістами-агрономами, характеризуються високою трудомісткістю, потребують значних часових витрат та залежать від кваліфікації експерта.

Системи штучного інтелекту, зокрема методи глибокого навчання, створюють можливості для суттєвого підвищення швидкості та точності діагностування захворювань рослин. Автоматизація процесів розпізнавання дозволяє виявляти патології на ранніх стадіях розвитку, коли застосування захисних заходів є найбільш ефективним. Відповідно зменшується використання пестицидів, мінімізація економічних втрат від епідемій та покращенню загальної продуктивності сільського господарства.

## Мета і задачі роботи

**Мета роботи** полягає у підвищенні точності розпізнавання та класифікації патологій листя сільськогосподарських рослин шляхом розробки методу з використанням згорткових нейронних мереж та механізмів регуляризації.

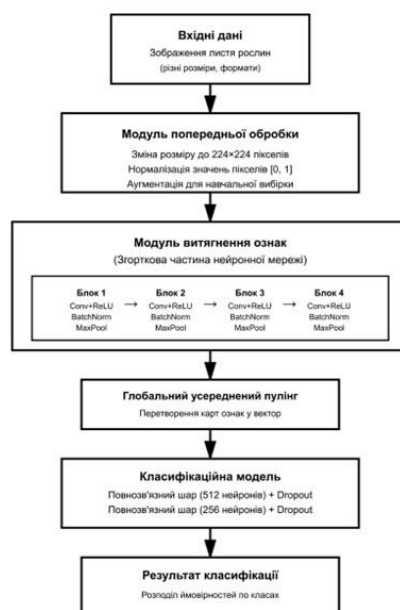
**Об'єкт дослідження** – процес автоматизованої діагностики захворювань рослин на основі аналізу зображень листя.

**Предмет дослідження** – моделі, методи та засоби класифікації патологій рослин з використанням згорткових нейронних мереж.

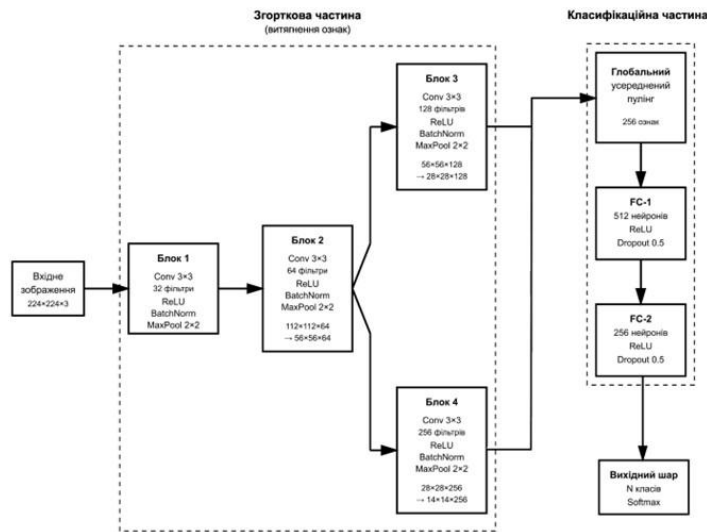
**Задачі дослідження:**

- провести аналіз існуючих методів та підходів до діагностики захворювань рослин з використанням методів машинного та глибокого навчання;
- розробити метод класифікації патологій листя з використанням згорткових нейронних мереж та механізмів регуляризації;
- спроектувати архітектуру нейронної мережі для ефективного витягнення візуальних ознак із зображень листя;
- програмно реалізувати метод розпізнавання та класифікації патологій листя сільськогосподарських рослин з використанням згорткових нейронних мереж та механізмів регуляризації;<sup>3</sup>
- провести експериментальне дослідження розробленого методу шляхом порівняння різних конфігурацій

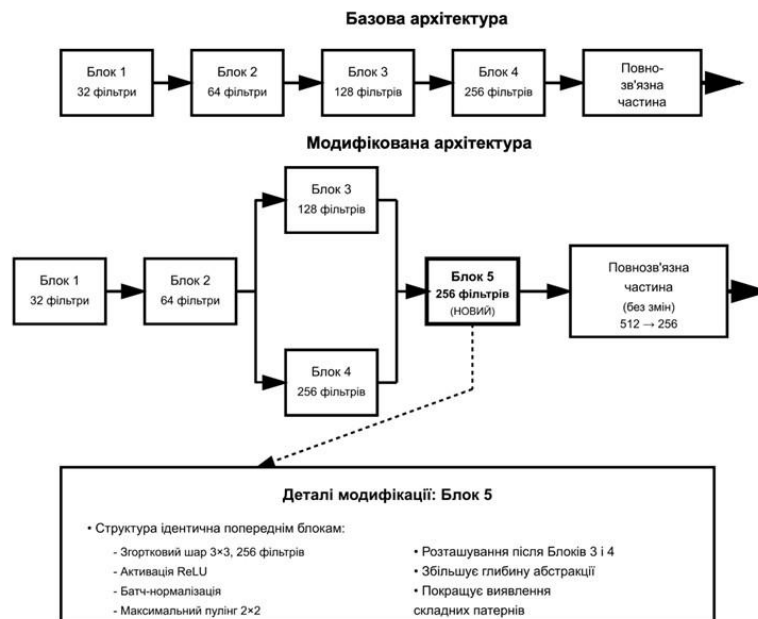
Загальна схема методу класифікації патологій листя



## Архітектура згорткової нейронної мережі



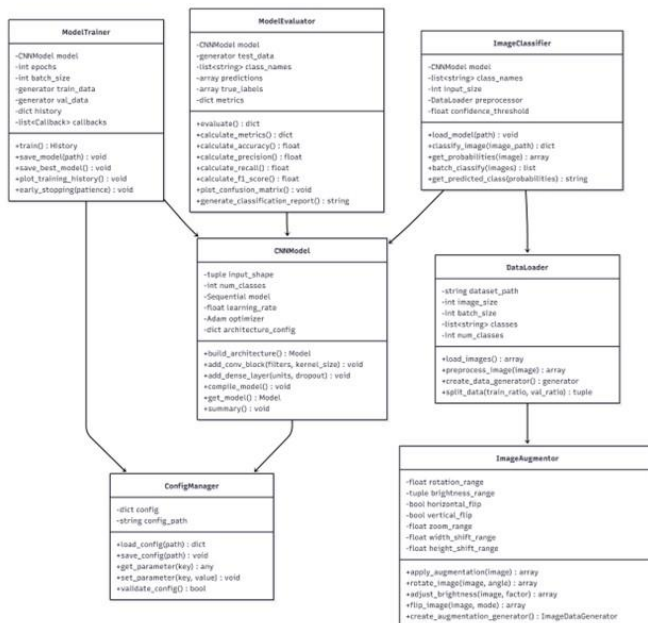
## Модифікована архітектура з додатковим блоком



## Схема попередньої обробки зображень

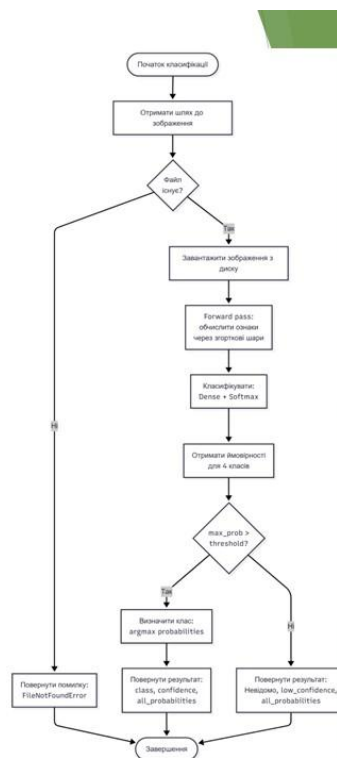


## Діаграма класів







Діаграма діяльності процесу класифікації зображення



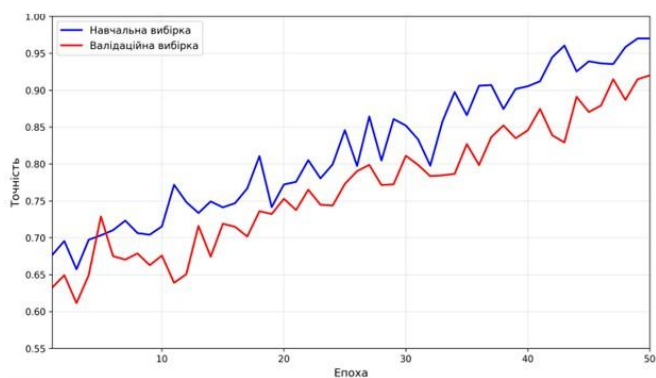
Графік навчання базової моделі



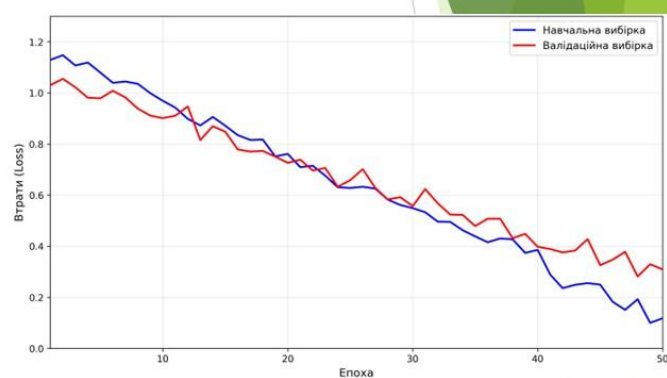
Графік втрат базової моделі




Графік навчання модифікованої моделі




Графік втрат модифікованої моделі




Порівняння точності базової та модифікованої моделі



## Якісні показники базової та модифікованої моделі



## Вплив аугментації на якісні показники моделі



## Висновки

1. Проведено аналіз існуючих методів та підходів до діагностики захворювань рослин з використанням методів машинного та глибокого навчання;
2. Розроблено метод класифікації патологій листя з використанням згорткових нейронних мереж та механізмів регуляризації;
3. Спроектовано архітектуру нейронної мережі для ефективного витягнення візуальних ознак із зображень листя;
4. Програмно реалізовано метод розпізнавання та класифікації патологій листя сільськогосподарських рослин з використанням згорткових нейронних мереж та механізмів регуляризації;
5. Проведено експериментальне дослідження розробленого методу шляхом порівняння різних конфігурацій архітектури та оцінки їх точності класифікації патологій рослин.

дякую за увагу!

# Anti-Plagiarism (UA) v-15.281 Educational

**The maximum coincidence with one document 1.0%**

Dictionary check: en\_US, ru\_RU, ua\_UA. **Errors in the documents: 9%**

ID: 252741 Title: КВАЛІФІКАЦІЙНА РОБОТА на тему Метод автоматичної класифікації патологій листя рослин на основі згорткових нейронних мереж Added in a DB: 2025-12-13 Authors: Валентин СОКОЛОВСЬКИЙ Heads: Едуард МАНЗЮК Consultants: Opponents:	Document		Sum coincidence on the DB	
	Symbols	Lexemes	Symbols	Lexemes
	110967	1684	2092 (2%)	33 (2%)

## Plagiarism sources

ID	Description	Plagiarism presence in the document	
		Symbols	Lexemes

## Протокол аналізу звіту подібності науковим керівником

Заявляю, що я ознайомився (-лась) з Повним звітом подібності, який був згенерований Системою виявлення і запобігання плагіату щодо роботи:

**Автор:** Валентин СОКОЛОВСЬКИЙ

**Співавтор:**

**Назва:** КВАЛІФІКАЦІЙНА РОБОТА на тему Метод автоматичної класифікації патологій листя рослин на основі згорткових нейронних мереж

**Науковий керівник:** Едуард МАНЗІЮК, д.т.н., доцент

**Підрозділ:** Кафедра комп'ютерних наук

**Коефіцієнт подібності 1:** 3.5%

**Коефіцієнт подібності 2:** 0.9%

**Мікропробіли:** 0

**Заміна букв:** 2

**Інтервали:** 0

**Білі знаки:** 0

**Дата створення звіту:** 2025-12-13 18:37:13.0

Після аналізу Звіту подібності констатую наступне:

Запозичення, виявлені в роботі є законними і не є плагіатом. Рівень подібності не перевищує допустимої межі. Таким чином робота незалежна і приймається.

Запозичення не є плагіатом, але перевищено граничне значення рівня подібностей. Таким чином робота повертається на доопрацювання.

Виявлено запозичення і плагіат або навмисні текстові спотворення (маніпуляції), як передбачувані спроби укриття плагіату, які роблять роботу невідповідною вимогам законодавства (Ст. 32. ЗУ Про вищу освіту, пункт 3.1, Ст. 42. ЗУ Про освіту) та вимог НАЗЯВО (Критерій 5), а також кодексу етики і процедурам. Таким чином робота не приймається.

Обґрунтування:

2025-12-13

Дата

експерт

*Петровевшиї С.Р. [підпис]*

**РІШЕННЯ ЕКСПЕРТНОЇ КОМІСІЇ КАФЕДРИ КОМП'ЮТЕРНИХ НАУК**

**ПРО ДОПУСК КВАЛІФІКАЦІЙНОЇ РОБОТИ ДО ЗАХИСТУ**

Назва кваліфікаційної роботи Метод автоматичної класифікації патологій листя рослин на основі згорткових нейронних мереж

Автор студент групи КНм-24-1 Валентин СОКОЛОВСЬКИЙ

Освітня програма Комп'ютерні науки

Рівень вищої освіти другий (магістерський)

Спеціальність 122 – Комп'ютерні науки

Науковий керівник: д.т.н., проф. каф. комп'ютерних наук Едуард МАНЗЮК

На основі аналізу кваліфікаційної роботи на дотримання вимог академічної доброчесності (у т.ч. відсутності ознак академічного плагіату) з урахуванням результатів перевірки роботи спеціалізованим програмними засобами комісія зробила такий висновок:

№	Висновок	Позначка про відповідність
1	Ознаки академічного плагіату	
1.1	Запозичення, виявлені в роботі, є законними і не є академічним плагіатом (далі – зазначаються підстави віднесення запозичень до правомірних, якщо потрібно). Робота приймається до захисту.	<i>відповідає</i>
1.2	Виявлені запозичення не є академічним плагіатом, розміщені в розділах, які не описують безпосередньо авторське дослідження, але кількість цитат перевищує обсяг, виправданий поставленою метою роботи (далі – зазначаються детальні та аргументовані підстави віднесення запозичень до правомірних). Робота приймається до захисту, але має бути відкоригована.	
1.3	Виявлені запозичення не є академічним плагіатом, але частково розміщені в розділах, які описують безпосередньо авторське дослідження, а кількість цитат перевищує обсяг, виправданий поставленою метою роботи. Робота може бути допущена до захисту після того як буде відкоригована та доопрацьована і успішно пройде повторну перевірку на академічний плагіат.	
1.4	Робота містить навмисні текстові спотворення, передбачувані спроби укриття текстових запозичень або інші прояви академічного плагіату. Робота містить фабрикацію або фальсифікацію даних. Робота не допускається до захисту.	
2	Інші види порушень академічної доброчесності	<i>відсутні</i>

Підтвердження:

*Запозичення, виявлені в роботі Валентина СОКОЛОВСЬКОГО, не є плагіатом, оскільки: запозичення розміщені в розділі огляду існуючих підходів, не описують безпосередньо авторську роботу і не стосуються її результатів; усі запозичення фрагментарні; до запозичень входять фрагменти, які не мають авторства і містять поширені конструкції та загальновідомі терміни, скорочення. Рівень подібності не перевищує допустимої межі. Таким чином, робота є законною та приймається до захисту.*

*Обсяг запозичень, визначений системами виявлення збігів/ідентичності/схожості:*

*- за системою Anti-Plagiarism: 1%;*

*- за системою StrikePlagiarism КП1: 3,45%, КП2: 0,9%.*

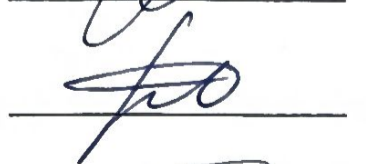
15.12.2025

Завідувач кафедри



Олександр БАРМАК

Гарант освітньої програми



Руслан БАГРІЙ

Керівник кваліфікаційної роботи



Едуард МАНЗЮК



## ВІДГУК ОПОНЕНТА

### на кваліфікаційну роботу магістра

студента *гр. КНм-24-1 Валентина СОКОЛОВСЬКОГО*

за темою *Метод автоматичної класифікації патологій листя рослин на основі згорткових нейронних мереж*

#### 1. Актуальність обраної теми

Актуальність обумовлена зростаючою необхідністю автоматизації процесів діагностики захворювань сільськогосподарських культур зумовлена актуальність обраної теми. Ручний огляд спеціалістів-агрономів вимагає значних часових витрат та залежать від досвіду експерта. На сьогодні існують можливості створення адаптивних систем моніторингу здоров'я рослин, здатних автоматично виявляти захворювання на ранніх стадіях розвитку використовуючи згорткові нейронні мережі, що дозволяє своєчасно застосовувати захисні заходи, зменшувати використання хімічних препаратів та мінімізувати економічні втрати від епідемій у сільському господарстві.

#### 2. Відповідність роботи предметній області спеціальності 122 Комп'ютерні науки та загальним вимогам до наукових робіт

Повністю відповідає предметній області спеціальності 122 Комп'ютерні науки магістерська робота, оскільки на застосуванні методів глибокого навчання, згорткових нейронних мереж, обробки та аугментації зображень ґрунтується. Фундаментальні знання у галузі комп'ютерних наук, такі як архітектури нейронних мереж, алгоритми оптимізації, методи регуляризації та експериментальне тестування використовує дослідження.

#### 3. Повнота розкриття мети та завдань дослідження

Повністю розкрито мету та завдання дослідження. Мету роботи чітко сформульовано автором – підвищення точності розпізнавання та класифікації патологій листя сільськогосподарських рослин шляхом розробки методу з використанням згорткових нейронних мереж та механізмів регуляризації.

#### 4. Наявність наукової новизни

Наукова новизна роботи полягає в удосконаленні методу класифікації патологій листя рослин, який відрізняється від існуючих застосуванням комбінації нормалізації та регуляризації у п'ятиблоковій архітектурі згорткової мережі.

## **5. Зміст кожного розділу роботи**

Чотири розділи містить робота. Аналіз існуючих методів діагностики захворювань рослин, характеристику задачі класифікації патологій листя, огляд архітектур згорткових нейронних мереж представлено в першому розділі. Концепцію та схему методу класифікації, архітектуру згорткової нейронної мережі, модифікацію моделі, формування навчальних даних та критерії оцінювання містить другий розділ. Програмній реалізації методу, вибору засобів та середовища розробки, архітектурі програмної реалізації присвячено третій розділ. Експериментальні дослідження, підготовку даних, навчання базової та модифікованої моделей, порівняльний аналіз та аналіз помилок містить четвертий розділ.

## **6. Ступінь розкриття теми роботи**

Повністю розкрито тему роботи. Автор аналізує проблематику автоматизованої діагностики захворювань рослин, розглядає існуючі архітектури згорткових нейронних мереж, обґрунтовує необхідність розробки удосконаленого методу. Наведено опис запропонованого методу на основі п'ятиблокової архітектури з механізмами нормалізації та регуляризації, представлено процес попередньої обробки зображень та аугментації даних. Якість методу перевірено на реальних наборах даних захворювань рослин.

## **7. Якість оформлення кваліфікаційної роботи**

Робота відповідає встановленим академічним стандартам якості оформлення кваліфікаційної роботи.

## **8. Недоліки кваліфікаційної роботи**

Результати експерименту слід було б порівняти з більш широким спектром сучасних архітектур глибокого навчання, таких як ResNet, EfficientNet.

## **9. Загальний висновок (допускається чи не допускається до захисту), якої оцінки заслуговує кваліфікаційна робота**

Робота має належний рівень виконання та забезпечення усіх необхідних вимог, наукову новизну отриманих результатів. Враховуючи якість проведених експериментальних досліджень, робота може бути допущена до захисту. Рекомендована оцінка – відмінно.

Опонент

*Д. М. М., професор*

*Тетяна ГОВОРУЦЕНКО*



## ВІДГУК НАУКОВОГО КЕРІВНИКА

### на кваліфікаційну роботу магістра

студента КНМ-24-1 Валентина СОКОЛОВСЬКОГО

за темою Метод автоматичної класифікації патологій листя рослин на основі згорткових нейронних мереж

#### 1. Актуальність теми

Традиційні методи виявлення захворювань сільськогосподарських культур, що базуються на візуальному огляді агрономами, є трудомісткими, тривалими та сильно залежать від кваліфікації спеціаліста. Застосування систем штучного інтелекту, зокрема методів глибокого навчання на основі згорткових нейронних мереж, дає змогу суттєво прискорити та підвищити точність діагностики. Автоматизоване виявлення патологій на ранніх стадіях дозволяє вчасно взяти захисних заходів, зменшити обсяги використання пестицидів, мінімізувати економічні втрати та підвищити загальну продуктивність сільського господарства.

#### 2. Відповідність роботи предметній області Стандарту спеціальності 122 Комп'ютерні науки

Робота відповідає предметній області спеціальності. У ній досліджуються та практично застосовуються згорткові нейронні мережі, методи глибокого навчання, техніки обробки й аугментації зображень, алгоритми класифікації, нормалізації та регуляризації даних, а також проводиться експериментальне тестування на реальних наборах даних. Отримані результати мають як фундаментальне значення для комп'ютерних наук, так і практичну цінність для автоматизації сільськогосподарського виробництва.

#### 3. Професійні та особистісні якості

Студент Валентин Соколовський продемонстрував високий рівень професійної компетентності у галузі комп'ютерних наук і глибокого навчання. Він відповідально та вчасно виконував усі етапи роботи, виявив глибоке розуміння архітектур згорткових нейронних мереж, принципів роботи з великими обсягами даних, наполегливість під час проведення експериментів та вміння критично аналізувати отримані результати.

#### 4. Ступінь самостійності під час виконання кваліфікаційної роботи

Студент виконав роботу з високим ступенем самостійності. Він самостійно провів аналіз літератури, запропонував власне удосконалення методу (комбінація нормалізації та регуляризації у п'ятиблоковій архітектурі згорткової мережі), спроектував архітектуру моделі, реалізував програмне забезпечення для попередньої

обробки зображень і навчання мережі, а також провів всебічне експериментальне дослідження.

#### **5. Наукова новизна та оригінальність запропонованих підходів**

Запропонований метод класифікації патологій листя рослин є оригінальним завдяки використанню комбінації сучасних технік нормалізації та регуляризації у п'ятиблоковій архітектурі згорткової нейронної мережі. Це дозволило підвищити точність класифікації на 4 % порівняно з базовою моделлю.

#### **6. Ступінь оволодіння методами дослідження**

Студент продемонстрував глибоке розуміння та вільне володіння сучасними методами комп'ютерного зору та машинного навчання: згортковими нейронними мережами, техніками аугментації, нормалізації, регуляризації, а також методами оцінки якості моделей на реальних наборах даних.

#### **7. Повнота та якість розкриття теми роботи**

Тема розкрита повною мірою. Робота має логічну структуру, ґрунтовний аналіз існуючих підходів, детальний опис розробленого методу, його програмної реалізації та всебічне експериментальне дослідження з використанням реальних даних.

#### **8. Логічність, послідовність, аргументованість, літературна грамотність викладення матеріалу**

Матеріал викладено логічно й послідовно: від постановки проблеми до розробки та експериментальної перевірки власного рішення. Висновки аргументовані, підкріплені кількісними метриками. Робота написана грамотною науковою мовою, легко читається, усі ідеї подано в логічній послідовності з належними обґрунтуваннями та посиланнями.

#### **9. Можливість практичного застосування кваліфікаційної роботи, окремих її частин**

Розроблений метод має широкі можливості практичного застосування: інтеграція у мобільні додатки для фермерів, системи моніторингу полів за допомогою дронів, стаціонарні системи контролю у теплицях та платформи точного землеробства. Застосування методу сприятиме ранньому виявленню захворювань, зменшенню використання пестицидів та зниженню економічних втрат.

#### **10. Висновок про можливість допуску кваліфікаційної роботи до захисту, на яку оцінку заслуговує робота**

Магістерська кваліфікаційна робота виконана на високому науковому та технічному рівні, відповідає всім вимогам, що пред'являються до робіт цього типу, і може бути допущена до публічного захисту.

Робота заслуговує оцінки «відмінно».

Керівник



д.т.н., професор каф. КН Едуард МАНЗЮК