

<https://doi.org/10.31891/2307-5732-2026-363-55>

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: [tskripnik1970@gmail.com](mailto:tskripnik1970@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 глибокого навчання, спрямований на підвищення точності діагностики та скорочення часу обчислень. Запропоновано модифіковану п'ятиблокову архітектуру згорткової нейронної мережі (на базі VGG16) з інтегрованими механізмами батч-нормалізації та dropout-регуляризації, що дозволило вирішити проблему перенавчання на обмежених вибірках.

Для забезпечення ефективності експериментальних досліджень реалізовано технологію розподіленого паралельного навчання, яка базується на принципі паралелізму даних із синхронізацією градієнтів. Такий підхід дозволив суттєво прискорити процес тренування моделі та забезпечити горизонтальну масштабованість системи. Описано технологічні аспекти створення програмного забезпечення, зокрема використання декларативного конфігурування та системи версіонування, що гарантує відтворюваність експериментів та надійність результатів.

Для експериментальних досліджень обрано датасет з чотирма класами хвороб листа. Проведено експериментальні дослідження на датасеті зображень листя квасолі у чотирьох категоріях. Встановлено, що запропонований метод досягає точності 91.2%, перевищуючи базову модель на 4%. Доведено критичний вплив аугментації даних на здатність моделі до узагальнення в умовах варіативності освітлення та ракурсів зйомки.

**Ключові слова:** згорткові нейронні мережі, класифікація патологій, розподілене навчання, паралельні обчислення, батч-нормалізація, аугментація даних, VGG16, Computer Vision.

SOKOLOVSKYI VALENTYN, MANZIUK EDUARD, BAHRII RUSLAN, SKRYPNYK TETIANA

Khmelnytskyi National University

## METHOD FOR PLANT LEAF PATHOLOGY CLASSIFICATION BASED ON CONVOLUTIONAL NEURAL NETWORKS USING DISTRIBUTED PARALLEL TRAINING TECHNOLOGIES

The effective operation of automated plant disease diagnosis systems is a critical factor in modern precision agriculture, requiring robust solutions for early detection of pathologies. Traditional diagnostic methods based on visual inspection are labor-intensive, subjective, and difficult to scale. This paper presents an improved method for classifying pathologies of agricultural plant leaves based on deep learning technologies, specifically aimed at increasing diagnostic accuracy and optimizing computational performance in high-load environments.

A modified five-block Convolutional Neural Network (CNN) architecture, derived from the VGG16 baseline, is proposed. The key architectural innovation involves the deep integration of batch normalization mechanisms after convolutional layers and dropout regularization in the fully connected layers. These modifications successfully addressed the issue of overfitting on limited datasets, ensuring the model's robustness to variations in input data and improving feature extraction capabilities for complex disease patterns.

To ensure the efficiency of experimental studies involving large-scale image datasets, a distributed parallel training technology was implemented. This approach relies on the principle of data parallelism with synchronous gradient updates across multiple computing nodes. The implementation allowed for a significant reduction in model training time and provided horizontal scalability of the system, making it suitable for processing big data. Furthermore, the paper describes the technological aspects of software creation, emphasizing the use of declarative configuration and a comprehensive versioning system (following MLOps principles). This approach guarantees the full reproducibility of experiments, systematic documentation of the development process, and reliability of the obtained results.

Experimental studies were conducted using a representative dataset of bean leaf images classified into four distinct categories. The results established that the proposed method achieves a classification accuracy of 91.2%, outperforming the baseline model by 4%. The study also proved the critical impact of data augmentation techniques on the model's generalization ability, particularly under conditions of variable lighting and diverse shooting angles. The obtained results confirm the practical value of the method for developing scalable automated diagnostic systems.

**Keywords:** Convolutional Neural Networks, pathology classification, distributed training, parallel computing, batch normalization, data augmentation, VGG16, Computer Vision, MLOps.

Стаття надійшла до редакції / Received 12.01.2026

Прийнята до друку / Accepted 11.02.2026

Опубліковано / Published 26.03.2026



This is an Open Access article distributed under the terms of the [Creative Commons CC-BY 4.0](https://creativecommons.org/licenses/by/4.0/)

© Соколовський Валентин, Манзюк Едуард, Багрій Руслан, Скрипник Тетяна

## **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 дають змогу з прийнятним рівнем точності ідентифікувати хвороби листя на різних етапах розвитку, також на тих етапах, коли використання заходів захисту є найбільш доцільним. Згорткові нейронні мережі (ЗНМ) демонструють високу ефективність у задачах розпізнавання образів та класифікації зображень завдяки наявній можливості отримувати 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, навчання глибоких архітектур на великих масивах графічних даних вимагає значних обчислювальних ресурсів і часу, що ускладнює проведення масштабних експериментів та оптимізацію гіперпараметрів.

Актуальною науковою задачею є розробка методів підвищення точності класифікації патологій листя рослин при забезпеченні стійкості до перенавчання, а також впровадження технологій розподіленого паралельного навчання для підвищення ефективності обчислювального процесу.

### **Аналіз досліджень та публікацій**

Автоматизована діагностика хвороб рослин за зображеннями листя має велике значення для аграрного сектору. Інфекційні ураження, викликані патогенними мікроорганізмами та шкідливими комахами, спричиняють суттєві збитки сільському господарству через зменшення обсягів врожаїв і погіршення якості сільськогосподарської продукції [1, 2]. Хворобливі стани негативно впливають на ключові фізіологічні процеси рослинних організмів – від фотосинтетичної активності до метаболізму поживних елементів, що відображається на загальній продуктивності культур. Видимі прояви захворювань – пігментовані ділянки, відмирання тканин, зміни забарвлення та порушення морфології листкової пластинки – створюють труднощі при ідентифікації через високу варіабельність симптоматики та подібність з непатологічними змінами, зокрема з мінеральним дефіцитом [3, 4].

Розпізнавання захворювань рослин реалізується через послідовність взаємопов'язаних операцій: формування колекції графічних матеріалів (фотографії листя томатів, картоплі, винограду, яблунь), первинну обробку візуальних даних (усунення завад, стандартизація колірних характеристик і контрасту, виділення патологічних зон), екстракцію інформативних параметрів (характеристики текстурних полів, кольорових властивостей, геометричних форм) і підсумкову ідентифікацію [5, 6]. Підготовчий етап обробки зображень відіграє вирішальну роль у ліквідації спотворень, які можуть перешкоджати коректному розпізнаванню. Уніфікація колірного представлення нівелює варіативність освітлювальних умов при фотозйомці в різні періоди доби чи за несприятливої погоди. Дослідницьке поле класифікаційних методів характеризується широким спектром альтернативних рішень.

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 поясненого 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 поясненого 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.

Нейромережеві структури становлять фундаментальну основу автоматизованого розпізнавання рослинних патологій завдяки властивості багаторівневого виділення ознак з візуальних даних без попереднього програмування. Багатошарова організація згорткових архітектур забезпечує прогресивне навчання представленням різного ступеня абстракції – від елементарних контурів і поверхневих патернів у поверхневих шарах до комплексних змістовних категорій у глибоких частинах мережі. Така властивість робить конволюційні моделі винятково придатними для розв'язання задач візуального аналізу, де рівнозначну

важливість мають як дрібні фрагменти, так і цілісна композиція зображення. До найпоширеніших нейромережових топологій належать VGG, ResNet, Inception, EfficientNet та їхні комбінації [2, 13]. Кожна топологічна конфігурація володіє специфічними характеристиками та перевагами, що визначають її застосовність до різноманітних аспектів діагностики рослинних захворювань.

Комбіновані методи, що інтегрують сильні сторони альтернативних топологій, зазвичай забезпечують вищу ефективність у порівнянні з моноархітектурними рішеннями [14-17]. Ансамблеві конструкції здатні об'єднувати прогнози множини різнотипних моделей, взаємно компенсуючи обмеження окремих складових через їхні переваги. Атенційні механізми надають моделі можливість концентруватися на найінформативніших регіонах візуальних даних. Просторовий атенційний модуль формує вагову карту, що характеризує значущість кожної локальної області. Канальний атенційний компонент встановлює, які фільтри ознак мають найбільшу релевантність для розв'язуваної задачі. Такі механізми можна впроваджувати в різноманітних місцях архітектури – після конволюційних блоків, перед операціями субдискретизації чи між послідовними рівнями мережі. Тренування атенційних компонентів здійснюється наскрізно спільно з іншими елементами мережі через алгоритм зворотного розповсюдження похибки.

#### **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.

Мета дослідження полягає у створенні удосконаленого підходу до автоматизованої ідентифікації хворобливих станів листя рослин сільськогосподарських культур через застосування згорткових нейромережових архітектур, що забезпечить вищий рівень точності діагностування.

Завдання:

- здійснити критичний огляд та систематизацію наявних технологічних рішень у сфері комп'ютерної діагностики фітопатологій із залученням алгоритмів машинного інтелекту та архітектур глибокого навчання;
- сформувати методологічний апарат ідентифікації листових патологій на основі застосування згорткових нейронних топологій із вбудованими технологіями запобігання перенавчанню;
- сконструювати нейромережову топологію, здатну до результативного виділення дискримінативних візуальних дескрипторів із графічних представлень листових поверхонь;
- імплементувати процедури первинної обробки та штучного збагачення графічного матеріалу з метою оптимізації навчального датасету та посилення генералізаційного потенціалу моделі;
- провести експериментальну верифікацію розробленого підходу через співставлення альтернативних конфігурацій нейромережової архітектури з подальшою кількісною оцінкою ефективності у розпізнаванні фітопатологічних станів.

#### **Виклад основного матеріалу**

Запропонована архітектура базується на послідовному з'єднанні п'яти згорткових блоків для отримання ознак та двох повнозв'язних шарів для класифікації. Вхідний шар отримує зображення. Система базується на VGG16, яка є згортковою нейронною мережею.

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 прості 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.

Представлена методологія спирається на технології глибинного навчання для ідентифікації хвороби рослин через аналіз фотографій листа. Центральна концепція полягає у самостійному виявленні характерних ознак нейромережею через багаторівневу систему згорткових обчислень, після чого відбувається остаточна категоризація через повнозв'язані компоненти. Перевага над класичними методиками полягає у відсутності необхідності ручного конструювання ознак - згорткові архітектури самостійно виявляють візуальні закономірності, притаманні конкретним захворюванням.

Обробка інформації відбувається поетапно. Початкова фаза передбачає підготовку вхідних даних, стандартизація розмірів та нормування піксельних величин забезпечують уніфікований формат для нейромережевої обробки. Додатково може застосовуватися фільтрація шумів та оптимізація контрасту для підвищення інформативності вхідного матеріалу.

Наступна фаза полягає в автоматичному виявленні характеристик оброблених фотографій. Згорткові компоненти послідовно виділяють патерни зростаючої складності, а саме початкові рівні фіксують базові елементи наприклад, контури, текстурні особливості, колірні градієнти та проміжні, при цьому комбінують їх у складніші конфігурації такі як форми уражень, специфічні візерунки, а найглибші створюють високоабстрактні репрезентації, характерні для окремих типів захворювань.

Завершальна фаза використовує виявлені характеристики для визначення категорії. Повнозв'язна частина аналізує отримані дані та генерує ймовірнісний розподіл по можливих класах патологій або здорового стану. Модель надає не категоричну відповідь, а ймовірнісний розподіл по всіх варіантах.

#### **Архітектурна організація системи розпізнавання**

Вхідний матеріал спочатку проходить модуль підготовки для нормалізації та стандартизації. Підготовлені дані потрапляють у згорткову секцію, що складається з ланцюга згорткових модулів. Кожен модуль реалізує операції згортки, нелінійної активації та субдискретизації для поступового виявлення та узагальнення візуальних характеристик.

Після згорткової секції карти ознак трансформуються у векторний формат для подачі у повнозв'язну частину. Повнозв'язні компоненти здійснюють фінальну обробку та формують вихідний ймовірнісний розподіл. Найімовірніший клас визначається як результат.

Така конфігурація забезпечує ефективну обробку знімків різноманітних культур та виявлення численних захворювань. Система демонструє стійкість до варіацій освітлення та кутів зйомки завдяки застосуванню аугментації під час тренування, що забезпечує інваріантність до трансформацій, а саме ротації, масштабування, зміни яскравості.

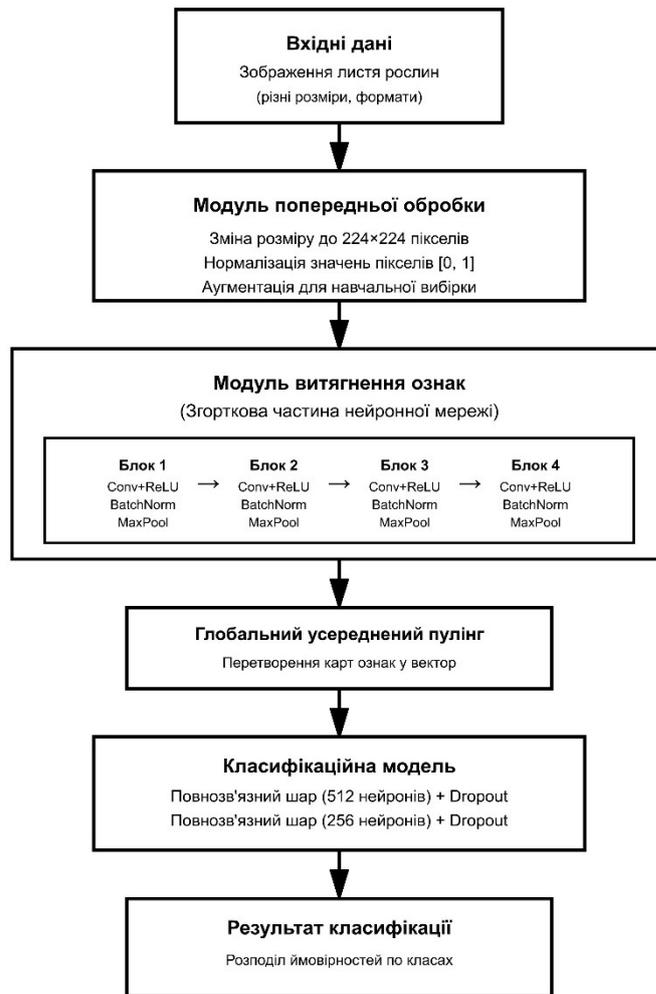


Рис. 1. Схема класифікації хвороби листя

Методологія інтегрує трансферне навчання для оптимізації процесу та покращення результативності. Базова частина може бути попередньо натренована на масивному загальному датасеті для засвоєння універсальних візуальних патернів, з наступною адаптацією до специфічної задачі розпізнавання фітопатологій через дообучення на цільових даних.

Вхідним форматом є RGB-зображення через те, що багато патологій проявляються саме через хроматичні зміни - пожовтіння, потемніння, плями специфічних кольорів. Чорно-біле представлення призвело б до втрати критичної діагностичної інформації.

Вихідні дані це вектор ймовірностей належності до кожної категорії, що дозволяє не лише отримати остаточне рішення, але й оцінити рівень упевненості моделі. Низька впевненість може сигналізувати про нетипові випадки або необхідність експертної верифікації.

#### Модифікована архітектура нейромережі

Нейромережева архітектура для класифікації фітопатологій побудована на послідовному поєднанні різномісних шарів, кожен з власною функціональністю у процесі обробки та виявлення ознак. Загальна конструкція включає згорткову секцію для виявлення просторових характеристик та повноз'язну для остаточної категоризації.

Запропонована модифікація передбачає інтеграцію додаткового згорткового модуля після четвертого базового блоку. П'ятий блок реплікує структуру попередніх: згортковий шар, ReLU-активація, пакетна нормалізація та максимальна субдискретизація. Застосовується 256 фільтрів 3×3, відповідно до четвертого блоку.

Обґрунтування модифікації базується на кількох міркуваннях. По-перше, додавання одного блоку є помірним ускладненням без надмірної архітектурної складності. По-друге, розміщення після базових модулів дозволяє формувати глибші абстрактні репрезентації на основі вже виділених ознак.

Додатковий модуль збільшує глибину згорткової секції з чотирьох до п'яти блоків, забезпечуючи додатковий етап обробки та узагальнення перед передачею у повноз'язну частину. Очікується покращене виявлення дрібних деталей патологій, критичних для точної класифікації.

Модифікована структура залишається логічною та послідовною. Після п'ятого блоку карти ознак мають меншу просторову розмірність проти базової архітектури при збереженні кількості каналів. Глобальний усереднений пулінг автоматично адаптується до зміненої розмірності.

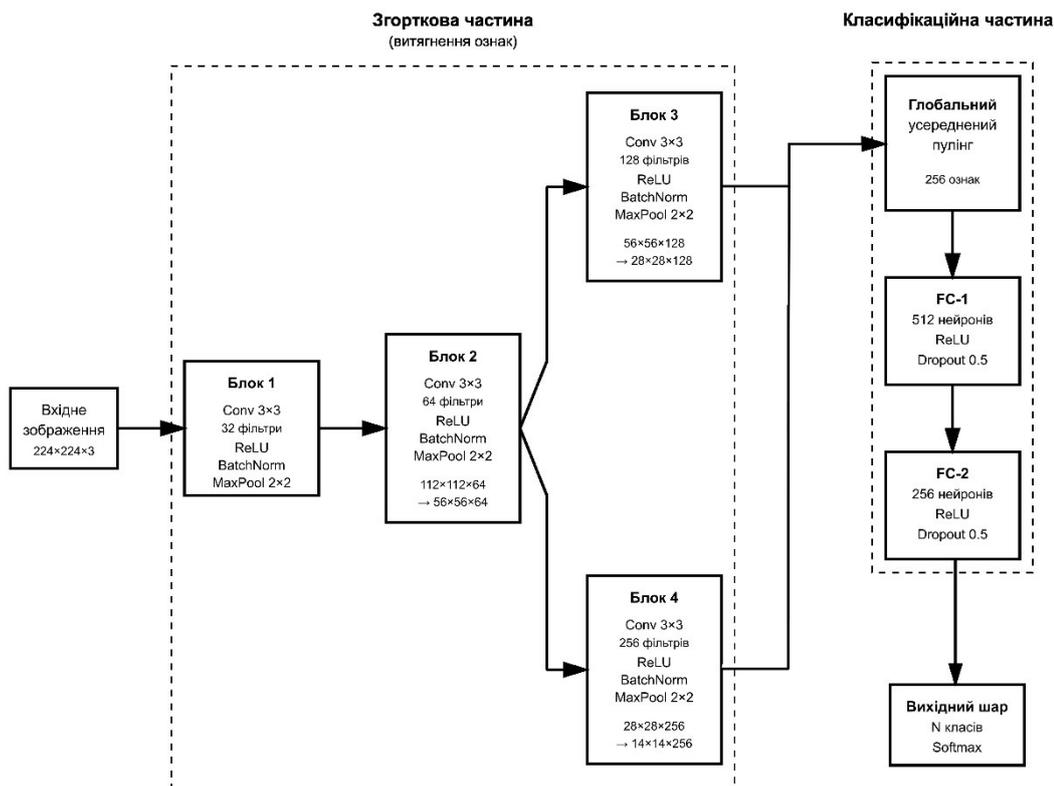


Рис. 2. Архітектура згорткової нейронної мережі

### Експериментальні дослідження

Тренування згорткової мережі потребує репрезентативної колекції зображень листя у різних станах. Якість та різноманітність навчального матеріалу безпосередньо визначає здатність моделі узагальнювати на невідомих зображеннях.

Вихідні знімки у датасеті характеризуються варіативною роздільною здатністю та співвідношенням сторін через різні джерела та обладнання. Це відображає реальні умови застосування - користувачі можуть фотографувати різними пристроями. Така гетерогенність ускладнює задачу, але робить її практично-орієнтованою.

Аугментація є критичною технікою для покращення якості тренування. Вона штучно розширює навчальну вибірку без збору нових фотографій. Важливіше - забезпечує інваріантність до трансформацій, що не змінюють семантику зображення. Всі техніки аугментації застосовуються стохастично та можуть комбінуватися. Одне оригінальне зображення може генерувати численні варіанти під час тренування. Кожна епоха бачить дещо модифіковані версії ідентичних знімків, що значно збагачує навчальний матеріал та покращує узагальнюючу здатність.

Аугментація виконується в реальному часі під час тренування, а не попередньо. Модифіковані версії генеруються безпосередньо перед подачею батча у мережу. Перевага підходу - відсутність необхідності зберігання великої кількості аугментованих знімків. Щоразу генеруються нові випадкові варіанти, забезпечуючи максимальну різноманітність.

Для верифікації працездатності запропонованої методології класифікації фітопатологій проведено серію експериментів з реальними зображеннями. Мета - визначення якості класифікації, порівняння архітектурних варіантів та аналіз впливу факторів на результат.

Початковий етап - тренування базової моделі без додаткової регуляризації для встановлення базового рівня якості та виявлення особливостей поведінки під час навчання.

Другий етап - тренування модифікованої моделі з механізмами регуляризації, пакетна нормалізація для верифікації покращення якості та зменшення перенавчання.

Результати експериментів демонструють покращення для всіх категорій. Здорові зразки розпізнаються з точністю 96,2% (покращення 4,4%). Кутова плямистість - 90,9% (+4,5%). Іржа квасолі - 91,8% (+4,6%).

Найбільший приріст спостерігається для класу інших патологій: точність зросла з 72,6% до 81,6%. Покращення на 9% є статистично значущим та демонструє, що додаткова регуляризація особливо ефективна для найскладніших категорій. Модель краще узагальнює на різноманітних прикладах цього гетерогенного класу. Кількість перехресних помилок між основними класами захворювань зменшилася. Лише 2% зображень кутової плямистості помилково класифікуються як іржа і навпаки, що вказує на виявлення тонших відмінностей між захворюваннями.

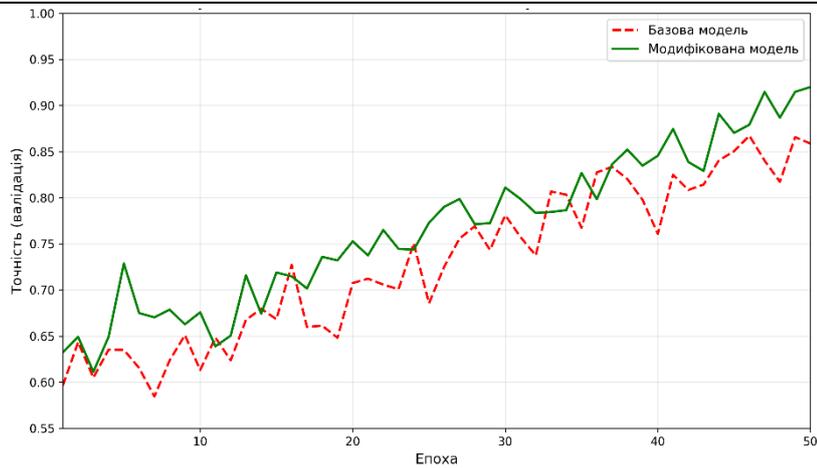


Рис.3. Значення характеристик моделей

Додатково обчислено інші метрики якості. Точність модифікованої моделі - 90,1% проти 85,8% базової. Серед зображень, класифікованих як певне захворювання, приблизно 90% справді мають це захворювання.

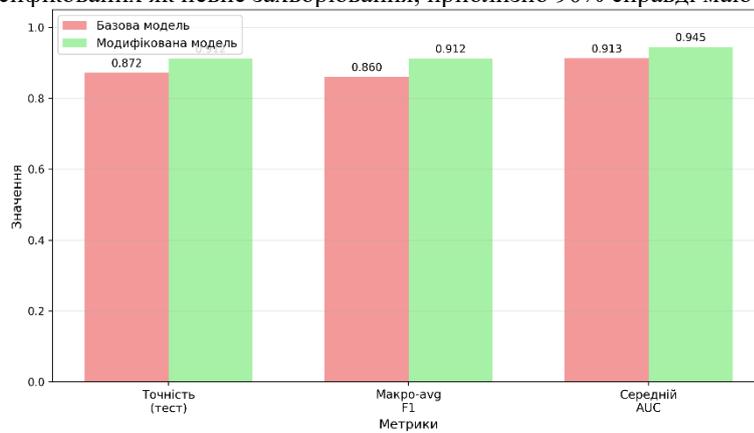


Рис. 4. Показники моделей класифікації

Повнота модифікованої моделі - 92,4% проти 87,5% базової, демонструючи виявлення приблизно 92% всіх випадків кожного захворювання. F1-міра - 91,2% для модифікованої та 86,0% для базової моделі.

Зведений графік наочно демонструє точність тренування та валідації для обох моделей на одному полотні, дозволяючи легко побачити відмінності у поведінці.

Важливим аспектом дослідження було визначення впливу аугментації на якість класифікації. Проведено додатковий експеримент, де модифікована модель тренувалася без аугментації на оригінальних зображеннях при незмінних інших параметрах.

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 з істотним розривом між навчальною та валідаційною точністю. Згідно з даними, модель без аугментації показала точність близько 78% та F1-міру близько 76,5% - класичний випадок оверфітінгу, коли модель надмірно адаптується до обмеженого набору тренувальних прикладів.

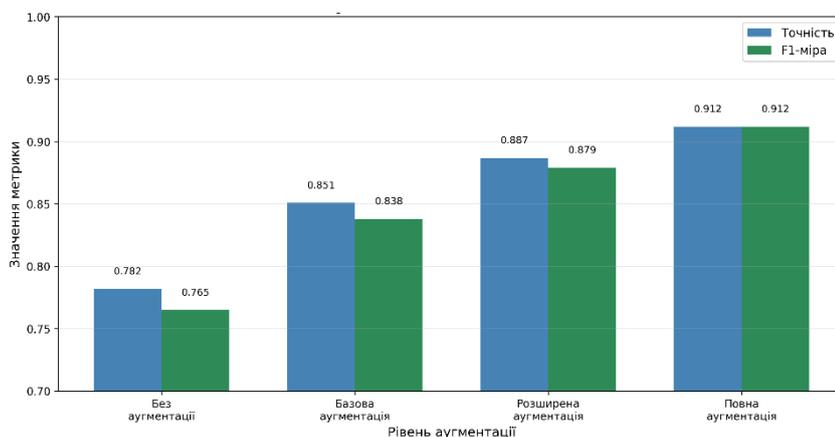


Рис.5. Порівняння впливу аугментації на якісні показники класифікації

Аналіз помилок виявив особливо погану продуктивність на випадках з незвичними кутами зйомки або нестандартним освітленням. Бачачи лише оригінальні зображення, модель не навчилася інваріантності до таких перетворень. Натомість модель з аугментацією регулярно бачила листки у різних орієнтаціях та умовах освітлення, навчившись виділяти суттєві ознаки захворювань незалежно від цих факторів.

Організація процесу розробки та дослідження системи здійснювалася з дотриманням принципів MLOps та декларативного опису інфраструктури, що дозволило забезпечити відтворюваність експериментів та ефективне використання обчислювальних ресурсів у розподіленому середовищі. Життєвий цикл розробки моделі був структурований на чотири технічні етапи.

Перша фаза була присвячена інженерії даних та встановленню базових метрик. На цьому етапі виконувалася підготовка датасету, його очищення від дублікатів та некоректних зображень, а також версіонування даних за допомогою DVC. Було налаштовано пайплайни препроцесингу та аугментації, а також навчено просту модель для визначення нижньої межі точності, від якої відштовхувалися подальші експерименти.

Друга фаза охоплювала ітеративний пошук оптимальної архітектури нейронної мережі. На цьому етапі виконувалася модифікація базової архітектури VGG16, інтеграція додаткових згорткових блоків та механізмів регуляризації (батч-нормалізація, dropout). Кожна зміна в архітектурі фіксувалася в системі трекінгу експериментів разом з отриманими метриками точності та втрат, що дозволяло порівнювати різні гіпотези та відкидати неефективні рішення.

Третя фаза зосереджувалася на оптимізації процесу навчання через впровадження технологій розподілених обчислень. Для прискорення тренування фінальної архітектури на повному наборі аугментованих даних було налаштовано кластер із підтримкою паралелізму даних. Це дозволило ефективно розпаралелити обчислення градієнтів та провести тонке налаштування гіперпараметрів у стислі терміни.

Четверта фаза включала фінальну валідацію та підготовку артефактів моделі. Отримана модель тестувалася на відкладеній вибірці для підтвердження її здатності до узагальнення. Результати аналізувалися за допомогою матриці помилок та метрик точності та повноти. Фінальним кроком став експорт ваг моделі та конфігураційних файлів у формат, придатний для подальшого розгортання в автоматизованих системах діагностики.

Контроль якості досліджень забезпечувався через автоматизоване логування всіх параметрів запуску. Такий підхід гарантує, що будь-який отриманий результат може бути верифікований та точно відтворений, що є критичною вимогою для наукових досліджень у галузі машинного навчання.

### Висновки

У роботі представлено комплексний підхід до розробки високоточної системи класифікації патологій листя сільськогосподарських рослин, що охоплює архітектурні, алгоритмічні та технологічні аспекти створення нейромережевих моделей.

Запропонована п'ятиблокова архітектура згорткової нейронної мережі з інтегрованими механізмами батч-нормалізації та dropout-регуляризації продемонструвала значне покращення точності класифікації до 91.2% порівняно з базовою моделлю. Особливо суттєвий приріст якості спостерігався для складних класів патологій, що свідчить про підвищену здатність моделі до виділення інваріантних ознак.

Впровадження технологій розподіленого паралельного навчання стало ключовим фактором оптимізації обчислювального процесу. Розподіл навантаження між обчислювальними вузлами на основі паралелізму даних дозволив ефективно обробляти великі масиви графічних зображень, суттєво скоротивши час експериментування та пошуку оптимальних гіперпараметрів. Це підтверджує доцільність використання методів високопродуктивних обчислень у задачах комп'ютерного зору.

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 подальшу модернізацію програмного продукту та передачу знань.

Отримані результати можуть бути використані для створення масштабованих автоматизованих систем діагностики захворювань рослин, здатних працювати в режимі реального часу та інтегруватися в сучасні агротехнічні платформи. Перспективи подальших досліджень включають адаптацію методу для інших культур та розробку ансамблевих підходів для підвищення надійності класифікації у складних польових умовах.

### 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. Arunnehr 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. 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
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>.