

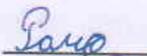
Вінницький національний технічний університет  
Факультет інтелектуальних інформаційних технологій та автоматизації  
Кафедра системного аналізу та інформаційних технологій

## МАГІСТЕРСЬКА КВАЛІФІКАЦІЙНА РОБОТА

на тему:

**«Інформаційна інтелектуальна технологія класифікації  
зображень у сфері зберігання овочів та фруктів»**

Виконав: студент 2 курсу, групи 2ІСТ-24м  
спеціальності 126 «Інформаційні системи та  
технології»

 Роман ЛІСАЧОВ

Керівник: д.т.н., проф., зав. каф. САІТ

 Віталій МОКІН

«27» \_\_\_\_\_ // \_\_\_\_\_ 2025 р.

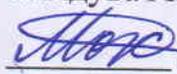
Опонент: д.т.н., проф. кафедри КН

 Ярослав ІВАНЧУК

«04» \_\_\_\_\_ // \_\_\_\_\_ 2025 р.

Допущено до захисту

Завідувач кафедри САІТ

 д. т. н., проф. Віталій МОКІН

«28» \_\_\_\_\_ // \_\_\_\_\_ 2025 р.

Вінниця ВНТУ – 2025 рік

Вінницький національний технічний університет  
Факультет інтелектуальних інформаційних технологій та автоматизації  
Кафедра системного аналізу та інформаційних технологій  
Рівень вищої освіти – другий (магістерський)  
Галузь знань – 12 Інформаційні технології  
Спеціальність – 126 Інформаційні системи та технології  
Освітньо-професійна програма – Інформаційні технології аналізу даних та зображень

ЗАТВЕРДЖУЮ  
Зав. кафедри САІТ,  
проф., д.т.н.

 Віталій МОКІН

(підпис)

«24» 09 2025 року

## ЗАВДАННЯ НА МАГІСТЕРСЬКУ КВАЛІФІКАЦІЙНУ РОБОТУ СТУДЕНТУ

Лісачову Роману Всеволодовичу

1. Тема роботи: «Інформаційна інтелектуальна технологія класифікації зображень у сфері зберігання овочів та фруктів»

керівник роботи: Віталій МОКІН, д.т.н., проф., зав. каф. САІТ

затверджені наказом ВНТУ від «24» 09 2025 року № 3/3

2. Термін подання студентом роботи «28» 11 2025 року

3. Вихідні дані до роботи:

Набір зображень овочів та фруктів, зібраних у датасеті Kaggle «Fruits and Vegetables Image Recognition»

<https://www.kaggle.com/datasets/kritikseth/fruit-and-vegetable-image-recognition>.

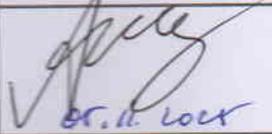
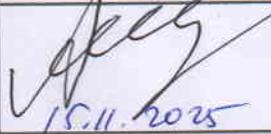
4. Зміст текстової частини:

- 1) Постановка задачі класифікації зображень овочів і фруктів у сфері їх зберігання;
- 2) Обґрунтування машинних рішень та вихідних даних;
- 3) Розроблення інформаційної інтелектуальної технології класифікації зображень овочів та фруктів;
- 4) Економічна частина.

5. Перелік ілюстративного матеріалу:

- 1) Блок-схема алгоритму розроблення та дослідження моделей;
- 2) Фрагмент датасету, який використано для випробування моделей;
- 3) Архітектура оптимальної моделі глибокого навчання;
- 4) Графіки результатів тренувань оптимальної інтелектуальної моделі;
- 5) Конфузійна матриця роботи оптимальної інтелектуальної моделі;
- 6) Таблиця порівняння параметрів та результатів роботи моделей;

- 7) Таблиця порівняння параметрів та результатів роботи розробленої моделі з аналогом;
- 8) UML-діаграма компонентів системи моніторингу зберігання фруктів і овочів на основі Інтернету речей.
6. Консультанти розділів роботи

| Розділ | Прізвище, ініціали та посада консультанта      | Підпис, дата   |   |
|--------|--|--|---|
|        |  | завдання видав   | завдання прийняв  |
| 4      | Олександр ЛЕСЬКО,<br>к. е. н., проф. каф. ЕПВМ | <br>05.11.2025 | <br>15.11.2025 |

7. Дата видачі завдання «25» 09 2025 року

### КАЛЕНДАРНИЙ ПЛАН

| № з/п | Назва та зміст етапу                                | Термін виконання |            | Примітка |
|-------|---|------------------|------------|----------|
|       |   | початок          | закінчення |          |
| 1     | Аналіз предметної області                           | 25.09.25         | 25.09.2025 | виконано |
| 2     | Вибір оптимальних інформаційних технологій          | 25.09.2025       | 05.10.2025 | виконано |
| 3     | Розроблення інформаційної технології                | 05.10.2025       | 25.10.2025 | виконано |
| 4     | Тренування та тестування моделей машинного навчання | 25.10.2025       | 05.11.2025 | виконано |
| 5     | Економічна частина                                  | 05.11.25         | 15.11.25   | виконано |
| 6     | Оформлення матеріалів до захисту МКР                | 15.11.25         | 25.11.25   | виконано |

Студент Роман Роман ЛІСАЧОВ

Керівник роботи Віталій Віталій МОКІН

## АНОТАЦІЯ

УДК 004.85+004.93+635

Лісачов Р. В. Інформаційна інтелектуальна технологія класифікації зображень у сфері зберігання овочів та фруктів. Магістерська кваліфікаційна робота зі спеціальності 126 – інформаційні системи та технології, освітньо-професійна програма – інформаційні технології аналізу даних та зображень. Вінниця: ВНТУ, 2025. 107 с.

На укр. мові. Бібліогр.: 33 назви; рис.: 34; табл.: 23.

Магістерська робота присвячена створенню інформаційної інтелектуальної технології класифікації зображень овочів і фруктів для контролю їх стану під час зберігання. Використано згорткові нейронні мережі, машинне навчання та аугментацію даних у середовищі Kaggle з використанням Python та бібліотек TensorFlow і Keras. На основі датасету “Fruits and Vegetables Image Recognition” побудовано низку моделей, серед яких обрано оптимальну за балансом між точністю розпізнавання та тривалістю виконання. Розроблену технологію можна впровадити на Raspberry Pi або NVIDIA Jetson Nano для автономного моніторингу продукції в овочесховищах.

Ілюстративна частина складається з 8 плакатів із результатами моделювання.

У розділі економічної частини розглянуто питання про доцільність розробки та впровадження інформаційної інтелектуальної технології класифікації зображень у сфері зберігання овочів та фруктів.

Ключові слова: інформаційна інтелектуальна технологія, класифікація зображень, нейронні мережі, MobileNetV2, EfficientNetB0, овочі і фрукти.

## ANNOTATION

Lisachov R. V. Information Intellectual Technology for Image Classification in the Field of Storage of Vegetables and Fruits. Master's Thesis in specialty 126 – Information Systems and Technologies, educational and professional program – Information Technologies for Data and Image Analysis. Vinnytsia: VNTU, 2025. 107p.

In Ukrainian. Bibliography: 33 titles; figures: 34; tables: 23.

The master's thesis is devoted to the creation of an intelligent technology for classifying images of fruits and vegetables to monitor their condition during storage. Convolutional neural networks, machine learning, and data augmentation were used in the Kaggle environment using Python and TensorFlow, and Keras libraries. Based on the dataset “Fruits and Vegetables Image Recognition”, several models were built, among which the optimal one was selected in terms of the balance between recognition accuracy and execution time. The developed technology can be implemented on Raspberry Pi or NVIDIA Jetson Nano for autonomous monitoring of products in vegetable storage facilities

The illustrative part consists of 8 posters with modeling results.

The economic section considers the feasibility of developing and implementing the proposed information intelligent technology for image classification in the field of vegetable and fruit storage.

Keywords: information intellectual technology, image classification, neural networks, MobileNetV2, EfficientNetB0, vegetables and fruits.

## ЗМІСТ

|  |    |
|--|----|
| ВСТУП.....   | 4  |
| 1 ПОСТАНОВКА ЗАДАЧІ КЛАСИФІКАЦІЇ ЗОБРАЖЕНЬ ОВОЧІВ І ФРУКТІВ У СФЕРІ ЇХ ЗБЕРІГАННЯ.....               | 6  |
| 1.1 Проблема класифікації зображень овочів та фруктів .....  | 6  |
| 1.2 Аналіз методів класифікації зображень овочів та фруктів.....                                     | 8  |
| 1.3 Аналіз проблемних питань класифікації зображень овочів і фруктів.....                            | 16 |
| 1.4 Висновки.....  | 20 |
| 2 ОБҐРУНТУВАННЯ МАШИННИХ РІШЕНЬ ТА ВИХІДНИХ ДАНИХ .....  | 22 |
| 2.1 Вибір мови програмування та бібліотек.....   | 22 |
| 2.2 Вибір оптимального середовища розроблення.....   | 24 |
| 2.3 Вибір датасету для тренування та тестування моделей.....   | 28 |
| 2.4 Висновки.....  | 32 |
| 3 РОЗРОБЛЕННЯ ІНФОРМАЦІЙНОЇ ІНТЕЛЕКТУАЛЬНОЇ ТЕХНОЛОГІЇ КЛАСИФІКАЦІЇ ЗОБРАЖЕНЬ ОВОЧІВ ТА ФРУКТІВ..... | 34 |
| 3.1 Розвідувальний аналіз даних .....  | 34 |
| 3.2 Передоброблення даних.....   | 37 |
| 3.3 Створення алгоритму побудови та дослідження моделей.....   | 41 |
| 3.4 Побудова, оцінка результатів та вибір оптимальної моделі .....                                   | 43 |
| 3.4.1 Побудова та результати роботи моделі Custom CNN .....  | 44 |
| 3.4.2 Побудова та результати роботи моделі на основі MobileNetV2 .....                               | 51 |
| 3.4.3 Побудова та результати роботи моделі на основі Efficient NetV0.....                            | 58 |
| 3.4.4 Вибір оптимальної моделі .....   | 65 |
| 3.5 Порівняння оптимальної інтелектуальної моделі з аналогом.....                                    | 66 |
| 3.6 Програмно-апаратні рішення .....   | 67 |
| 3.7 Висновки.....  | 70 |
| 4 ЕКОНОМІЧНА ЧАСТИНА.....  | 72 |
| 4.1 Науковий аудит науково-дослідної роботи.....   | 72 |
| 4.2 Комерційний та технологічний аудит науково-технічної розробки.....                               | 75 |

|  |                                     |
|--|-------------------------------------|
| 4.3 Розрахунок узагальненого коефіцієнта якості розробки .....   | 77                                  |
| 4.4 Розрахунок витрат на здійснення науково-дослідної роботи .....   | 79                                  |
| 4.4.1 Витрати на оплату праці .....  | 79                                  |
| 4.4.1.1 Основна заробітна плата дослідників.....   | 79                                  |
| 4.4.1.2 Основна заробітна плата робітників.....  | 80                                  |
| 4.4.1.3 Додаткова заробітна плата дослідників та робітників.....   | 82                                  |
| 4.4.2 Відрахування на соціальні заходи.....  | 82                                  |
| 4.4.3 Сировина та матеріали .....  | 83                                  |
| 4.4.4 Розрахунок витрат на комплектуючі .....  | 84                                  |
| 4.4.5 Спецустаткування для наукових (експериментальних) робіт.....   | 85                                  |
| 4.4.6 Програмне забезпечення для наукових (експериментальних) робіт.....                                   | 86                                  |
| 4.4.7 Амортизація обладнання, програмних засобів та приміщень.....   | 87                                  |
| 4.4.8 Паливо та енергія для науково-виробничих цілей .....   | 89                                  |
| 4.4.9 Службові відрядження .....   | 90                                  |
| 4.4.10 Витрати на роботи, які виконують сторонні підприємства, установи і організації.....                 | 90                                  |
| 4.4.11 Інші витрати .....  | 91                                  |
| 4.4.12 Накладні (загальновиробничі) витрати .....  | 91                                  |
| 4.5 Оцінювання важливості та наукової значимості науково-дослідної роботи.....                             | 93                                  |
| 4.6 Розрахунок економічної ефективності науково-технічної розробки .....                                   | 94                                  |
| 4.7 Висновки.....  | 98                                  |
| ВИСНОВКИ .....   | 100                                 |
| СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ.....  | 100                                 |
| Додаток А (обов'язковий) Технічне завдання.....  | 108                                 |
| Додаток Б (обов'язковий) Протокол перевірки кваліфікаційної роботи на наявність текстових запозичень ..... | <b>Error! Bookmark not defined.</b> |
| Додаток В (довідковий) Лістинг програми.....   | 111                                 |
| Додаток Г (обов'язковий) Ілюстративна частина.....   | 116                                 |

## ВСТУП

**Актуальність теми.** У сучасних умовах розвитку агропромислового комплексу питання ефективного та якісного зберігання овочевої продукції набуває особливого значення. Значні обсяги овочів, які потребують тривалого зберігання, вимагають впровадження новітніх технологій контролю та моніторингу їх стану. Традиційні методи контролю, що базуються на ручній перевірці, є малоефективними, потребують значних трудових ресурсів та не гарантують своєчасного виявлення дефектів.

Використання систем комп'ютерного зору та технологій класифікації зображень дозволяє автоматизувати процес моніторингу якості зберігання овочів, оперативно виявляти пошкодження продукції або порушення умов зберігання. Це забезпечує можливість зниження втрат продукції, покращення умов її зберігання та оптимізації роботи овочесховищ [1].

Актуальність дослідження зумовлена необхідністю впровадження сучасних цифрових технологій для підвищення ефективності аграрного виробництва та забезпечення продовольчої безпеки.

**Мета і завдання роботи.** Метою кваліфікаційної роботи є підвищення точності та ефективності класифікації зображень овочів та фруктів шляхом розроблення інформаційної інтелектуальної технології.

Для досягнення поставленої мети необхідно вирішити такі завдання:

- провести аналіз існуючих методів розпізнавання зображень, що можуть бути застосовані для моніторингу овочесховищ;
- вибрати середовище розроблення та необхідні інструменти для вирішення поставленої задачі;
- підібрати датасет для подальшої роботи;
- провести розвідувальний аналіз даних;
- побудувати моделі та виконати класифікацію зображень;
- оцінити результати роботи моделей та обрати оптимальну модель;

- запропонувати конкретні програмно-апаратні рішення застосування інформаційної інтелектуальної технології для моніторингу овочів та фруктів;
- оцінити практичні можливості впровадження методів класифікації зображень для контролю стану овочевої продукції.

**Об’єктом дослідження** є процеси автоматизованої класифікації та контролю стану овочевої продукції під час її зберігання.

**Предметом дослідження** є інформаційна інтелектуальна технологія класифікації зображень, що застосовуються для моніторингу стану овочів у сховищах.

**Методи дослідження.** У дослідженнях використовуються методи розвідувального аналізу, машинного навчання інтелектуальних моделей та методи статистичного аналізу даних для оптимізації параметрів моделей та оцінювання їх точності.

**Наукова новизна одержаних результатів** полягає у тому, що дістав подальший розвиток метод класифікації зображень овочів та фруктів, за рахунок оптимізації згорткової нейромережевої моделі Efficient NetB0, що дозволяє підвищити точність та ефективність цієї класифікації. Ця технологія забезпечує більш досконалий моніторинг стану овочів та фруктів у сховищах.

**Практичне значення роботи** полягає у створенні інформаційної інтелектуальної технології для автоматизації запропонованого методу та у можливості використання результатів для впровадження автоматизованих систем сортування продуктів на складах, у супермаркетах, а також у портах для контролю якості товарів.

#### **Публікації результатів магістерської кваліфікаційної роботи.**

Опубліковано тези на Міжнародній науково-практичній інтернет-конференції студентів, аспірантів та молодих науковців «Молодь в науці: дослідження, проблеми, перспективи (МН-2026)» (Вінниця, 2025-2026 рр.) [2]. Результати роботи моделей CCN представлено у ноутбучі Каггл [Classifications of fruit and vegetable images.](#)

# 1 ПОСТАНОВКА ЗАДАЧІ КЛАСИФІКАЦІЇ ЗОБРАЖЕНЬ ОВОЧІВ І ФРУКТІВ У СФЕРІ ЇХ ЗБЕРІГАННЯ

## 1.1 Проблема класифікації зображень овочів та фруктів

Точне, швидке й стабільне розпізнавання зображень овочів і фруктів сьогодні має велике значення, адже саме воно лежить в основі автоматизації багатьох процесів, пов'язаних із їхнім зберіганням.

Використання технологій комп'ютерного зору в цій сфері суттєво покращує контроль якості продукції, спрощує сортування врожаю та допомагає відстежувати стан і ступінь стиглості плодів. Крім того, такі технології дають змогу надавати покупцям більше інформації — про поживну цінність, свіжість, походження та умови вирощування продуктів.

Стрімкий розвиток інформаційних інтелектуальних технологій, зокрема методів машинного навчання, нейронних мереж, а особливо глибокого навчання, значно розширив потенціал автоматизованих систем обробки зображень. Сучасні моделі здатні розпізнавати складні патерни, враховувати найменші візуальні відмінності між видами та сортами плодів, а також проводити багатокласову класифікацію з високою точністю навіть у випадках неоднорідних чи шумних даних [3].

Крім технічних переваг, автоматизація процесів класифікації овочів і фруктів має важливе економічне значення. У багатьох країнах спостерігається нестача кваліфікованої робочої сили та зростання її вартості, що стимулює підприємства впроваджувати інноваційні рішення, здатні зменшити витрати та підвищити продуктивність. Автоматизовані системи класифікації дозволяють забезпечити стабільність якості продуктів і зменшити людський фактор, що особливо важливо у великих переробних та логістичних центрах.

Економічна значущість цієї проблеми відображається й у динаміці світового ринку переробки фруктів та овочів. За прогнозами, обсяг цього ринку

у 2025 році становитиме 10,42 млрд доларів США, а до 2034 року очікується його зростання до приблизно 17,69 млрд доларів США. Середньорічний темп зростання (CAGR) у період з 2024 по 2034 рік оцінюється на рівні 6,07%, що свідчить про активне впровадження цифрових та автоматизованих технологій у виробництво та обробку продукції (рис. 1.1).

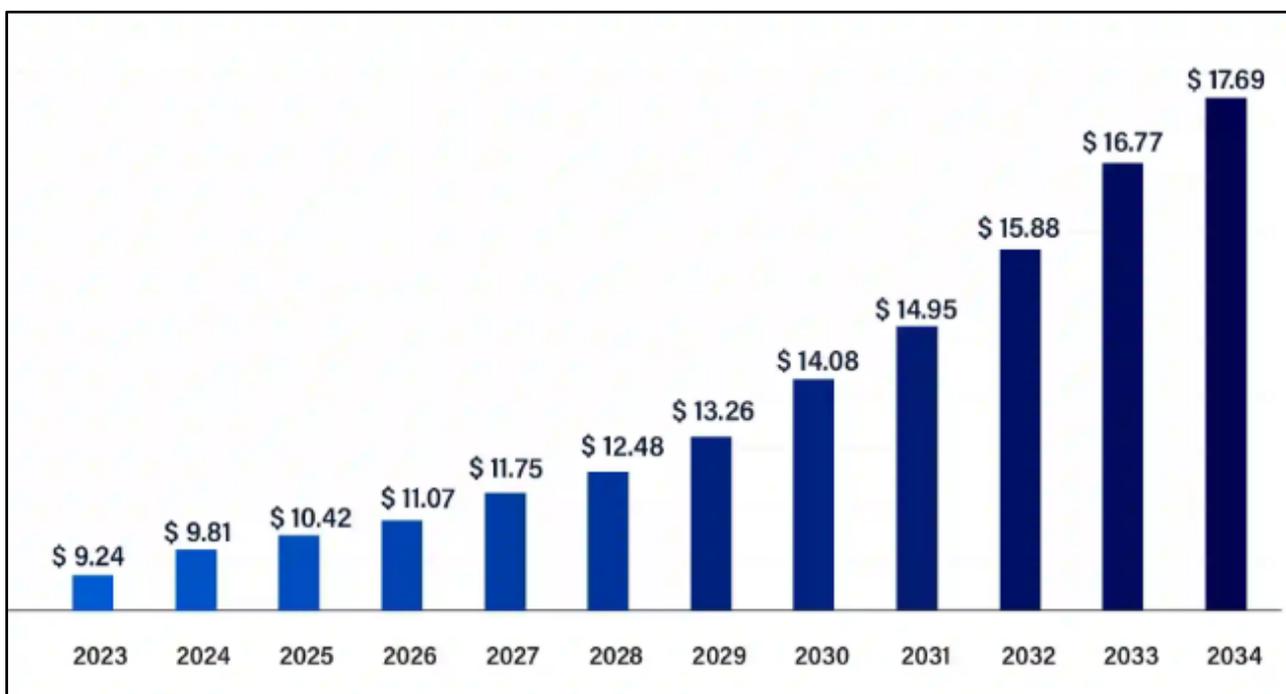


Рисунок 1.1 – Обсяг ринку переробки фруктів та овочів з 2022 по 2032 рік [4]

Подовження часу, протягом якого свіжі овочі та фрукти не псуються, а також зменшення їхніх втрат під час зберігання вважають одним із найактуальніших напрямів досліджень, адже це впливає і на якість харчування, і на економічні витрати.

Термін придатності харчових продуктів — це період, у який їжа залишається безпечною та зберігає свої властивості, відповідаючи встановленим нормам.

До важливих показників якості належать харчові, гігієнічні та сенсорні характеристики, що допомагають визначити придатність продукту до споживання. Точне визначення терміну придатності в конкретних умовах дає можливість краще організувати зберігання і транспортування та знаходити

способи його подовження через покращення технологій і рецептур.

Класифікація зображень фруктів і овочів є технічно складним, але важливим завданням, оскільки вона сприяє підвищенню контролю якості й оптимізації виробничих процесів. Це підсилює потребу в подальших дослідженнях і розвитку сучасних методів аналізу візуальних даних, що дає змогу точніше оцінювати стан продукції та робити контроль більш надійним і ефективним.

## **1.2 Аналіз методів класифікації зображень овочів та фруктів**

Методи класифікації зображень овочів та фруктів еволюціонували разом із розвитком комп'ютерних технологій і теорії штучного інтелекту. Якщо на початкових етапах дослідники використовували прості алгоритми на основі аналізу кольору чи форми, то сьогодні застосовуються складні моделі глибокого навчання, здатні не тільки класифікувати плоди з високою точністю, але й допомагати у прийнятті рішень у сільському господарстві та торгівлі.

Справжній прорив відбувся після 2012 року, коли на конкурсі ImageNet модель AlexNet, побудована на згорткових нейронних мережах, перевершила всі попередні методи. CNN стали універсальним інструментом для класифікації зображень, зокрема і для овочів та фруктів.

Основна відмінність CNN полягає у здатності самостійно виділяти релевантні ознаки. Якщо традиційні методи потребували ручного втручання, то згорткові мережі навчаються багаторівневим представленням даних. На перших шарах вони "бачать" прості структури, як краї чи кути, на наступних — більш складні форми, а на вищих рівнях — абстрактні характеристики, які допомагають моделі відрізнити сорти, визначати дефекти чи навіть оцінювати ступінь стиглості плоду.

Крім того, згорткові нейронні мережі добре працюють у ситуаціях, коли умови зйомки можуть відрізнитися [3]. Завдяки шарам пулінгу вони стійкі до невеликих змін масштабу, повороту або освітлення, тож «не ламаються» через

дрібні відмінності між зображеннями. Це робить такі моделі значно надійнішими в реальних умовах, де неможливо створити однакове середовище для кожного фото і зображення часто виходять різними.

Незважаючи на потужність глибокого навчання, побудова великих CNN з нуля потребує значних обчислювальних ресурсів і великих обсягів розмічених даних. У багатьох практичних випадках, зокрема при класифікації специфічних видів овочів та фруктів, такі ресурси можуть бути обмеженими. У таких ситуаціях ефективним рішенням є використання знань, отриманих моделлю при навчанні на великому наборі даних, для розв'язання іншої, подібної задачі.

У класифікації зображень часто застосовуються моделі, попередньо навчені на ImageNet — наборі, що містить мільйони зображень тисяч об'єктів. Такі моделі вже здатні виділяти широкий спектр візуальних ознак, корисних у задачах комп'ютерного зору, включаючи розпізнавання форм, текстур і кольорів.

Машинне навчання в задачах класифікації овочів і фруктів зазвичай базується на використанні архітектур ResNet, Inception, VGG або EfficientNet. Залежно від специфіки даних, застосовують різні стратегії: "заморожування" більшості шарів із навчанням лише класифікаторів або "тонку настройку" (fine-tuning), коли навчаються й частини базової моделі [3]. Останній підхід дозволяє краще адаптувати модель до нових характеристик зображень і досягти вищої точності, особливо при наявності достатньої кількості даних.

Завдяки здатності економити ресурси та забезпечувати високу ефективність навіть при обмежених наборах даних, машинне навчання стало ключовим інструментом у створенні систем комп'ютерного зору для агропромислових завдань.

Щоб і надалі підвищувати точність і швидкість роботи систем, які класифікують зображення овочів і фруктів, дослідники все частіше використовують комбіновані або гібридні підходи. Один із найпоширеніших варіантів — застосування бібліотеки OpenCV для підготовки зображень до того, як вони потраплять у модель глибокого навчання. Така попередня обробка

може включати сегментацію, очищення кадру від шумів, корекцію освітлення та підсилення контрастності. Усе це дає моделі CNN більш «якісний» вхід і помітно спрощує її подальшу роботу.

Іншим напрямом гібридних підходів є комбінування ознак, виділених різними методами. Наприклад, можна вилучати класичні ознаки (колірні гистограми, текстурні характеристики LBP чи HOG, морфологічні параметри), використовуючи OpenCV або Scikit-image, а також глибокі ознаки з CNN. Потім їх можна об'єднувати та подавати у класифікатор, наприклад, SVM або Random Forest, реалізовані у Scikit-learn. Поєднання різних ознак може дати більш стійкі та точні результати у складних умовах [3].

Ефективність різних методів вирішення поставленої задачі розпізнавання овочів та фруктів для подальшої їх обробки та зберігання продемонстровано у таблиці 1.1.

Таблиця 1.1 – Порівняння методів класифікації зображень овочів та фруктів

| <b>Підхід</b>     | <b>Основна ідея</b>                                      | <b>Переваги</b>                                | <b>Недоліки</b>   | <b>Приклади застосування</b>                                  |
|-------------------|--|--|---|---|
| Традиційні методи | Використання ручно обраних ознак: колір, форма, текстура | Простота реалізації, низькі вимоги до ресурсів | Сильна залежність від умов зйомки, низька точність при складних завданнях | Визначення стиглості за кольором, сортування плодів за формою |

Продовження таблиці 1.1.

| <b>Підхід</b>                      | <b>Основна ідея</b>  | <b>Переваги</b>  | <b>Недоліки</b>  | <b>Приклади застосування</b>   |
|------------------------------------|--|--|--|--|
| CNN<br>(глибоке навчання)          | Автоматичне виділення ознак завдяки багат шаровій структурі мереж                            | Висока точність, стійкість до шумів та освітлення, відсутність потреби у ручному виділенні ознак | Потреба у великих наборах даних та значних обчислювальних ресурсах | Класифікація сортів яблук, виявлення дефектів плодів                   |
| Перенос знань (Knowledge Transfer) | Використання моделей, попередньо навчених на великих наборах, для нових завдань              | Економія ресурсів, висока ефективність навіть при малих даних                                    | Менша гнучкість, потреба у налаштуванні                            | Використання ResNet, VGG, EfficientNet для класифікації овочів         |
| Гібридні підходи                   | Поєднання CNN з класичними методами (OpenCV, Scikit-image) для виділення та об'єднання ознак | Стійкість і точність, поєднання інтерпретованих та абстрактних ознак                             | Складність реалізації, потреба у більшій кількості етапів обробки  | Сегментація об'єктів OpenCV + CNN + класифікатори SVM чи Random Forest |

Усталені методи оцінки якості та визначення терміну придатності зазвичай базуються на мікробіологічних, фізико-хімічних і сенсорних методах аналізу [5]. Проте такі підходи потребують суворого дотримання стандартизованих процедур і часто є руйнівними для самого продукту. Крім того, сенсорна оцінка передбачає значну участь людини та має певну суб'єктивність, що підвищує вартість, складність і похибку вимірювань.

У таблиці 1.2 наведено порівняльну характеристику переваг і недоліків традиційних динамічних моделей та моделей машинного навчання.

Таблиця 1.2 – Переваги та недоліки традиційних динамічних моделей та моделей машинного навчання

| Принцип              | Метод              | Пре-диктор                                  | Переваги  | Недоліки  |
|----------------------|--------------------|---|---|---|
| Традицій-на динаміка | Хімічна кінетика   | Загальна кількість пластинок (ТРС)          | Проста форма, що підходить для різних прогнозів термінів придатності  | Зазвичай використовується разом із рівнянням Арреніуса, враховуючи лише вплив температури на зміни якості   |
|                      | Мікроб-на кінетика | Специфічний організм, що спричиняє псування | Окрім температури, також враховувався вплив факторів навколишнього середовища, таких як вологість та значення рН, на термін зберігання. | Мікробні показники тісно корелюють зі змінами якості харчових продуктів і не підходять для прогнозування терміну придатності свіжих продуктів з коротшими термінами зберігання. |

Продовження таблиці 1.2.

| Принцип          | Метод   | Предиктор  | Переваги   | Недоліки   |
|------------------|---|--|--|--|
| Машинне навчання | Нейронна мережа, машина опорних векторів регресії | Сенсорні, фізико-хімічні та мікро-біологічні показники | Немає потреби розуміти конкретні основні принципи, що спричиняють погіршення якості харчових продуктів, що зменшує помилки, спричинені недостатнім дослідженням цих принципів. | Не вміє виражати та аналізувати внутрішній зв'язок між входом та виходом |

Завдяки своїм перевагам — високій надійності, об'єктивності, точності, економічній ефективності та мінімальним часовим затратам — методи машинного навчання дедалі частіше застосовуються у сучасних дослідженнях для прогнозування та оцінки якості й терміну придатності харчових продуктів.

Нині дослідники активно поєднують технології неруйнівного контролю свіжості фруктів і овочів із моделями машинного навчання. Результати неруйнівного контролю використовують як вхідні дані для моделі, яка після навчання на великій вибірці зразків здатна визначати стан якості плодів. Залежно від отриманої інформації про якість, регулюють умови зберігання та параметри навколишнього середовища, щоб досягти продовження терміну придатності фруктів і овочів [5].

На рисунку 1.2 представлено узагальнені структурні схеми різних алгоритмів машинного навчання та їх застосування для контролю якості й визначення терміну придатності фруктів і овочів.

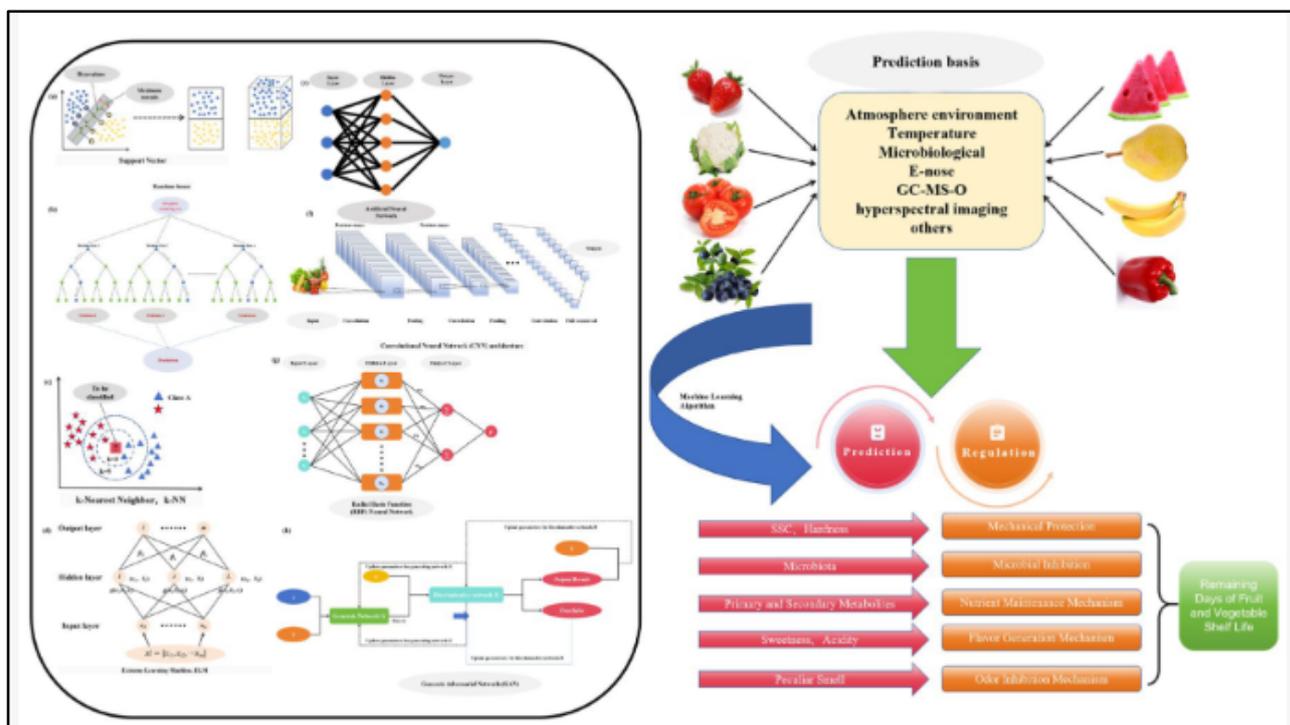


Рисунок 1.2 – Схематичне зображення алгоритмів машинного навчання та їх застосування в контролі терміну придатності та якості фруктів та овочів: ( а ) метод опорних векторів, ( б ) випадковий ліс, ( с ) k-найближчих сусідів, ( d ) екстремальна машина навчання, ( е ) штучна нейронна мережа, ( f ) згорткова нейронна мережа, ( г ) радіальна базисна нейронна мережа, ( h ) генерація змагальних мереж [5]

Якість плодів є ключовим фактором не лише для споживачів, а й для виробників і постачальників. Одним із ефективних підходів є класифікація фруктів за стадіями дозрівання, що дозволяє застосовувати оптимальні умови зберігання на кожному етапі.

На рисунку 1.3 подано архітектуру GAN, яку застосовано для класифікації свіжості полуниці на основі її зображень, із прикладами свіжих і зіпсованих плодів [5].

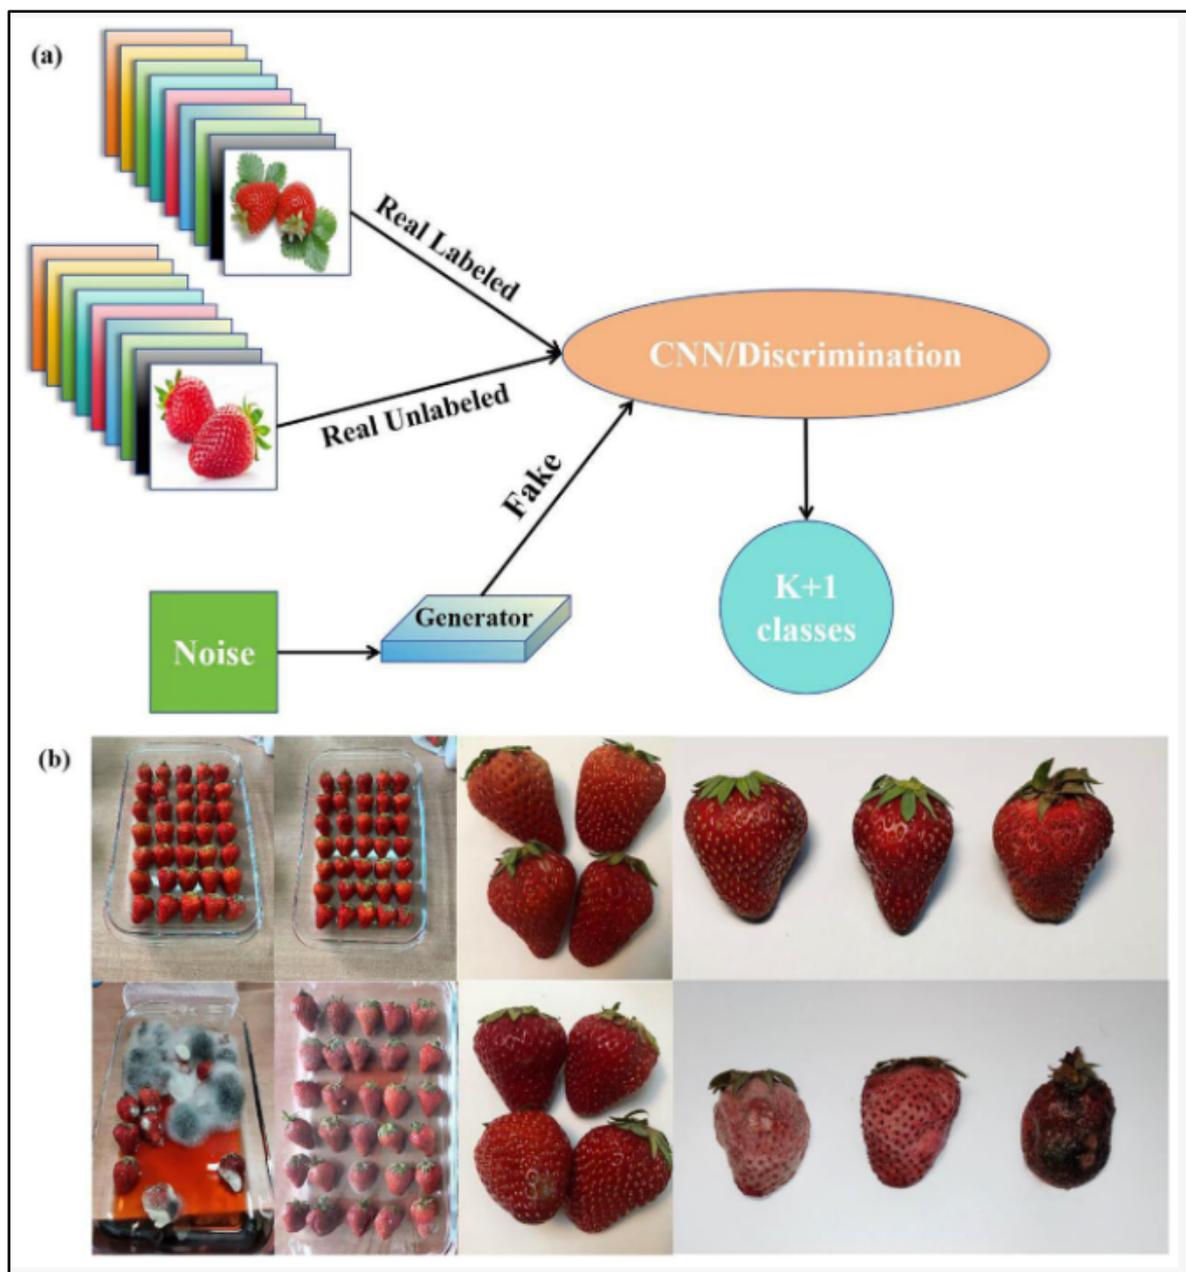


Рисунок 1.3 – Архітектура генеративно-змагальної мережі (GAN) для класифікації свіжості полуниці на основі зображень та схематичних діаграм свіжої та гнилої полуниці

Так, Бенмуна та співавт. використали гіперспектральні дані у видимому та ближньому інфрачервоному діапазонах для неруйнівного визначення ступеня зрілості яблук сорту Фудзі [5]. У дослідженні було зібрано спектральні дані 1000 зразків яблук на різних стадіях дозрівання (у діапазоні 172–450 нм). Для класифікації зразків застосовано згорткову нейронну мережу (CNN), результати якої порівняли з моделями, побудованими на основі штучних

нейронних мереж (ANN), методу опорних векторів (SVM) та методу k-найближчих сусідів (k-NN).

Отримані результати засвідчили, що модель CNN продемонструвала найвищу точність класифікації (CCR) — 96,5%, тоді як середня точність для моделей ANN, SVM і k-NN становила відповідно 89,5%, 95,93% та 91,68%.

Це дослідження зробило вагомий внесок у розвиток технологій автоматичної класифікації фруктів і овочів на різних етапах дозрівання, а також у створення ефективних стратегій їх зберігання, що сприяє збереженню якості продукції та зменшенню втрат ресурсів.

### **1.3 Аналіз проблемних питань класифікації зображень овочів і фруктів**

У сучасних технологіях класифікації зображень овочів і фруктів спостерігаються важливі тенденції, що підвищують практичність, адаптивність і придатність таких систем до реальних, зокрема польових, умов. Розвиток апаратних засобів і нових архітектур глибокого навчання значно розширює можливості автоматизованих рішень у агропромисловості.

По-перше, моделі глибокого навчання демонструють істотно вищу точність класифікації порівняно з традиційними методами машинного навчання, які спиралися на ручне чи напівручне вилучення ознак. Глибокі мережі самостійно формують багаторівневі представлення даних, що покращує здатність розпізнавати дрібні відмінності між класами та працювати з великими й різномірними наборами зображень.

Водночас дослідження має обмеження, що визначають напрями подальшого розвитку. Нинішня модель класифікує об'єкти лише за зовнішнім виглядом і використовує один ракурс зображення, що не завжди дозволяє врахувати зміни форми, текстури та кольору — важливі для точного розпізнавання, особливо у випадку пошкоджених або частково перекритих плодів.

У майбутньому планується впровадити багаторакурсне бачення. Модель навчатиметься й тестуватиметься на даних, зібраних з різних кутів огляду, що забезпечить повніше просторове уявлення про об'єкт. Для перевірки роботи системи в реальному часі на конвеєрі передбачено використання спеціального освітлювального боксу з кількома камерами, який дасть змогу одночасно знімати плоди з різних сторін і підвищити точність класифікації, як показано в таблиці 1.3.

Таблиця 1.3 – Точність методів прогнозування ідентифікації фруктів і овочів [6]

| Ref.                   | Data size  | Technique   | Precision |
|------------------------|--|-------------|-----------|
| Villalba et al., 2022  | 650 photographs of bananas   | AGR-DL      | 96.00%    |
| Lu, Tan & Jiang, 2021  | BIFROST and Kaggle websites of plant leaves (beans, eggplant, cucumber, tomato, pumpkin, ginger and soy) | ResNet      | 83.00%    |
|                        |  | VGGNet      | 92.00%    |
|                        |  | DCNN        | 88.46%    |
| Ati et al., 2022       | 90 tests   | CNN         | 95.00%    |
| Tommy D. Beltran 2024  | Real and Synthetic data (Apples, Strawberry, Mango)  | MobileNetV2 | 94,25%    |
|                        |  | VGG16       | 95,51%    |
| (Hussain et al., 2022) | 10,000 images of vegetables and fruits   | DCNN        | 96.00 %   |
| (Arévalo, 2021)        | 360 ripe and unripe peaches  | CNN         | 95.31%    |

По-друге, особливо актуальні моделі, оптимізовані для використання при обмежених ресурсах. Архітектури на зразок MobileNet-V2, EfficientNet-V2-B0 і NASNet-Mobile демонструють гарну компромісну продуктивність: вони менш "важкі", споживають менше пам'яті та енергії, але при цьому забезпечують

достатньо високі показники точності. У дослідженні щодо вирощування цитрусових таких моделей порівнювали для класифікації стану хвороби плодів, і MobileNet-V2, наприклад, виявилась однією з кращих кандидатур при обмежених ресурсах для мобільної системи (рис. 1.4) [7].

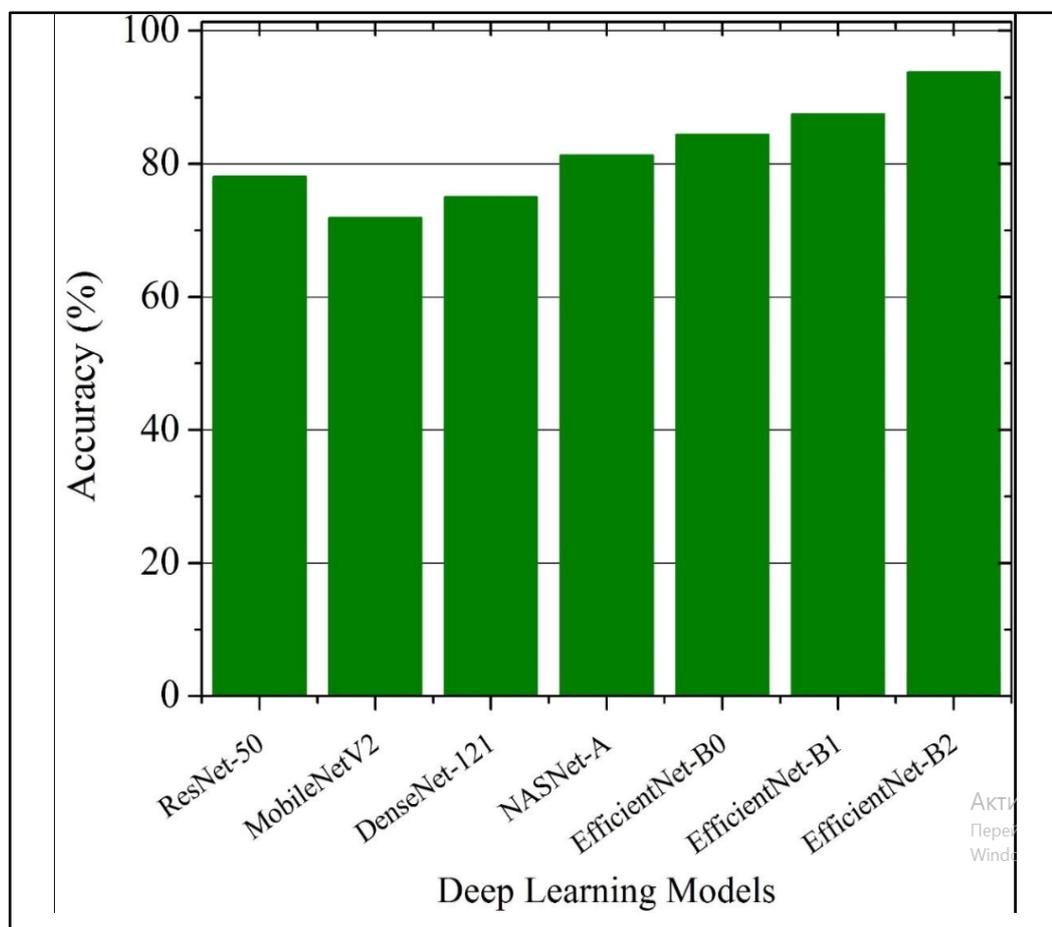


Рисунок 1.4 – Порівняння точності між моделями

По-третє, при роботі з невеликими наборами даних велика увага звертається на надлишкове навчання (overfitting) та стратегії, які допомагають цьому запобігати. Наприклад — діагностика захворювань у бананів із допомогою мобільного застосунку (рис. 1.5).

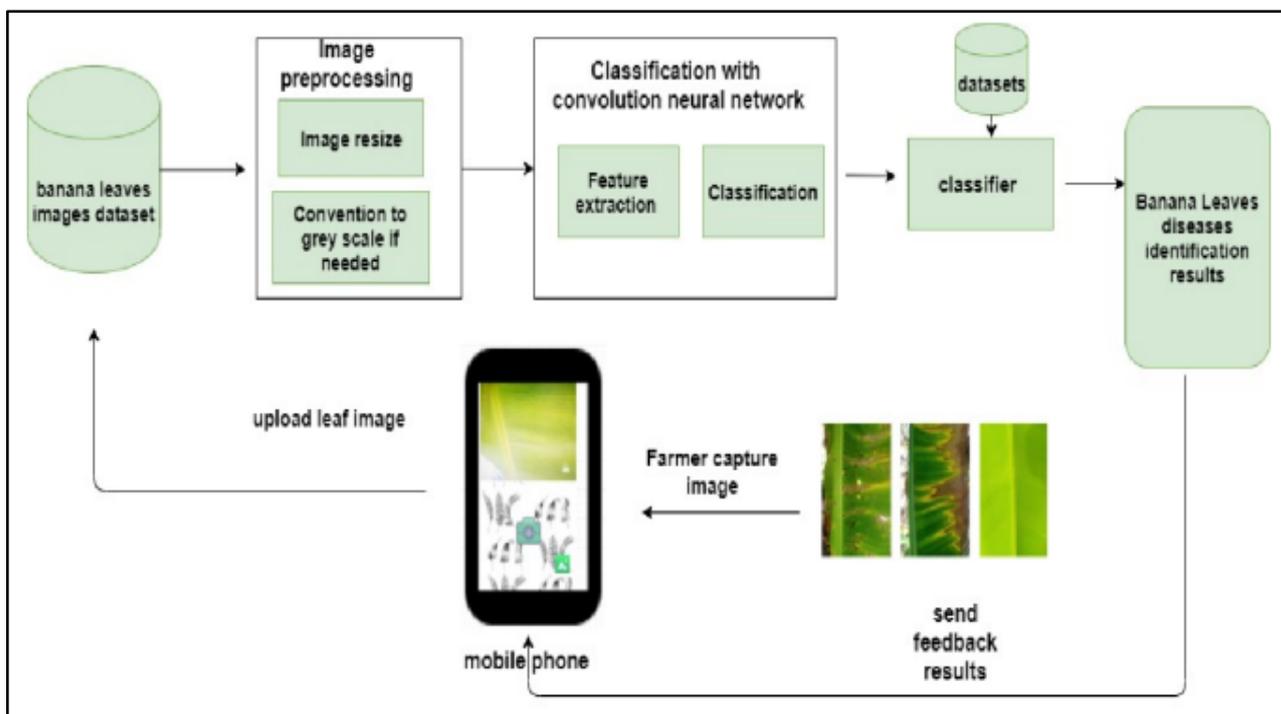


Рисунок 1.5 – Блок-схема розгортання мобільного додатку [8]

У цьому дослідженні використовували моделі ResNet152 і InceptionV3 для попереднього навчання, і однією з моделей було обрано ту, яка мала найкращий баланс між точністю і ресурсозатратністю для використання на Android-пристроях. Такі застосунки демонструють високу точність — понад 99 % у лабораторних (контрольованих) умовах — і надзвичайно добрі результати при тестуванні в польових умовах.

У харчовій промисловості системи автоматичного сортування плодів стають дедалі досконалішими. Крім простої класифікації за кольором чи розміром, використовується комп'ютерний зір у поєднанні з робототехнікою: камери високої роздільної здатності відслідковують кожен плід на конвеєрі, автоматичні сортувальні механізми (роборуки, механічні пристрої) відкидають або направляють продукти відповідно до класу якості. Це скорочує тривалість людської праці, зменшує відходи (наприклад, пошкоджені чи недозрілі фрукти не потрапляють у пакування), а також підвищує стандарти упаковки і презентації продукції.

З'являється також тенденція до використання мультиспектральних чи гіперспектральних зображень, ІЧ-світла або теплових камер для оцінки стану плодів чи листя [6]. Такі методи дозволяють бачити ознаки, які невидимі неозброєним оком чи при звичайному освітленні — наприклад, захворювання, вологість, внутрішні дефекти чи стрес, що виник через недостатню зволоженість чи хвороби. Це особливо корисно для передбачення якості під час зберігання чи транспортування.

Сьогодні все частіше поєднують технології комп'ютерного зору з IoT, хмарними сервісами та обробкою даних у реальному часі. Це можуть бути датчики, підключені пристрої, дрони чи безпілотники, які роблять знімки з висоти та одразу аналізують їх або надсилають у хмару для подальшої обробки. Такий підхід дає змогу швидко виявляти перші ознаки хвороб чи появу шкідників, а також допомагає оптимізувати використання добрив і води для зрошення, роблячи весь процес більш точним і ефективним [6].

Проте є й виклики: моделі, навчання яких ведеться в лабораторних умовах, можуть втрачати точність у польових умовах через змінне освітлення, об'єкти, що частково закривають плоди (листя, інші плоди), або через інші джерела шуму. Також, забезпечення достатньої кількості якісно розмічених даних залишається проблемою, особливо для рідкісних сортів або дефектів.

## **1.4 Висновки**

У першому розділі розглянуто актуальність задачі класифікації зображень овочів і фруктів, яка має велике практичне значення для автоматизації контролю якості, сортування та моніторингу стану продукції. Також було проведено аналіз існуючих методів розпізнавання зображень, що можуть бути застосовані для моніторингу овочесховищ, що дозволило оцінити їхні можливості, обмеження та перспективи використання в реальних виробничих умовах.

Проаналізовано основні етапи розвитку методів класифікації — від простих алгоритмів аналізу кольору та форми до сучасних моделей глибокого навчання, зокрема згорткових нейронних мереж (CNN), що забезпечують високу точність розпізнавання.

Показано, що використання машинного навчання та гібридних підходів дозволяє ефективно вирішувати задачі навіть за обмежених ресурсів і невеликих обсягів даних. Визначено актуальні напрями розвитку технологій — застосування мобільних і хмарних систем, поєднання комп'ютерного зору з IoT, робототехнікою та мультиспектральним аналізом для підвищення ефективності моніторингу.

Таким чином, для успішного вирішення поставленої задачі необхідна розробка та впровадження інформаційної інтелектуальної технології на основі адаптованої моделі глибокого навчання (CNN) з використанням попередньо натренованих моделей із вагами, отриманими під час навчання на великому наборі зображень, що забезпечує високу точність та практичну придатність.

## 2 ОБҐРУНТУВАННЯ МАШИННИХ РІШЕНЬ ТА ВИХІДНИХ ДАНИХ

### 2.1 Вибір мови програмування та бібліотек

Хоча на перший погляд може здатися, що будь-яка мова з достатньою кількістю математичних функцій може бути використана для класифікації зображень, але практика показує, що Python має низку переваг у порівнянні з іншими поширеними інструментами.

У сучасних системах зберігання важливим завданням є виявлення початкових ознак псування плодів. Для цього використовуються як видиме світло, так і гіперспектральні зображення. Python підтримує роботу з багатоканальними даними, що дозволяє будувати моделі для розпізнавання дефектів, непомітних людському оку.

Зберігання фруктів і овочів вимагає не лише періодичного аналізу стану продукції, але й обробки даних у реальному часі. Це важливо для великих складів, де сотні тонн продукції постійно перебувають під ризиком псування. Python, попри те, що традиційно вважається інтерпретованою мовою, має низку інструментів, що дозволяють реалізовувати системи швидкої обробки даних.

Завдяки поєднанню Python із графічними процесорами (GPU) через TensorFlow або PyTorch можлива паралельна обробка великої кількості зображень. Це особливо актуально для систем, що мають відстежувати стан кожного ящика фруктів у реальному часі. Практичні дослідження підтверджують, що використання GPU-обчислень дозволяє скоротити час аналізу зображень у десятки разів, забезпечуючи вчасне реагування на загрозу псування [9].

Окремої уваги заслуговує інтеграція Python з комплексними системами управління складськими приміщеннями. У багатьох випадках сучасні склади вже оснащені програмними модулями для відстеження логістики, контролю клімату та автоматизації процесів. Python завдяки своїй сумісності з

протоколами обміну даними (наприклад, MQTT, OPC-UA) легко вбудовується в такі системи, забезпечуючи додатковий рівень інтелектуального аналізу [10].

Для попередньої обробки зображень активно використовуються OpenCV та Pillow [11]. OpenCV забезпечує широкий спектр функцій, включаючи зміну розміру зображень, конвертацію у відтінки сірого, виявлення країв і контурів, а також фільтрацію шуму. Ці можливості особливо корисні при аналізі плодів, що зберігаються в холодильних камерах, де освітлення може бути нерівномірним, а на поверхні об'єктів часто з'являються дефекти. Використання OpenCV дозволяє ефективно виділяти корисну інформацію, мінімізуючи вплив зовнішніх факторів. Pillow, у свою чергу, забезпечує простіший інструментарій для базових операцій, що робить його зручним у швидких експериментах та роботі з невеликими наборами даних.

Не менш важливим є поєднання Python із бібліотеками для аналізу та організації даних. NumPy та Pandas стали стандартом для роботи з великими наборами інформації, дозволяючи зберігати, обробляти та структурувати метадані про продукцію [12]. Наприклад, під час тривалого зберігання фруктів і овочів може збиратися інформація не лише про візуальні характеристики плодів, але й про умови їх зберігання — температуру, вологість, рівень газообміну. Інтеграція цих параметрів із зображеннями у єдиний набір даних забезпечує комплексний підхід до прогнозування терміну придатності [13].

Окремо слід виділити бібліотеки Matplotlib та Seaborn, які дозволяють візуалізувати результати досліджень. Побудова графіків точності класифікації, відображення процесу навчання моделей або демонстрація помилкових класифікацій у вигляді теплових карт надає можливість глибшого розуміння роботи алгоритмів. Це особливо важливо в агропромислових дослідженнях, де кінцевим користувачем часто є не програміст, а агроном чи працівник складу, якому потрібно наочно бачити результати системи [14].

C++ вважається потужним вибором для високопродуктивних обчислень, особливо в умовах, коли потрібна оптимізація швидкодії. Дійсно, бібліотека

OpenCV була спочатку створена саме для C++ і зберігає виняткову ефективність при роботі з великими масивами зображень. Проте використання C++ у сфері досліджень класифікації зображень овочів та фруктів виявляється менш зручним через складність синтаксису, триваліший цикл розробки та меншу кількість високорівневих бібліотек для глибокого навчання [15].

Java іноді використовується у промислових застосуваннях для побудови стабільних та масштабованих систем, проте її застосування в машинному навчанні є обмеженим. Попри наявність таких бібліотек, як DeepLearning4j, їхня популярність і рівень підтримки значно поступаються TensorFlow чи PyTorch. Це створює бар'єри для дослідників, яким потрібні сучасні рішення та доступ до прикладів з відкритих джерел [16].

R традиційно використовується в статистиці та аналізі даних, і хоча вона має пакети для машинного навчання (наприклад, caret), її можливості в обробці зображень залишаються доволі обмеженими. У випадку задачі класифікації зображень фруктів і овочів R більше підходить для допоміжного статистичного аналізу, ніж для побудови складних моделей глибокого навчання [17]

## **2.2 Вибір оптимального середовища розроблення**

Вибір середовища розроблення є важливим етапом побудови системи класифікації зображень овочів та фруктів, оскільки саме воно визначає ефективність процесу навчання, можливості масштабування, зручність роботи з даними та подальше розгортання моделі. Сучасні інструменти машинного навчання пропонують широкий спектр функцій для створення, тестування та відлагодження нейронних мереж.

Одним із найзручніших середовищ для навчання моделей є Google Colab (Collaboratory) — безкоштовна хмарна платформа від Google, яка також базується на Jupyter Notebook [18]. Colab надає користувачам можливість працювати з Python-кодом без встановлення програмного забезпечення на

локальний комп'ютер, використовуючи віртуальні машини з доступом до GPU або TPU. Це робить платформу зручною для початкових експериментів, навчання невеликих моделей або проведення демонстраційних проєктів. Серед переваг Colab — інтеграція з Google Drive, що спрощує обмін даними та зберігання результатів, а також простота підключення до GitHub. Однак обмеженням є тривалість сесій (до 12 годин) і випадкове відключення під час тривалого навчання великих моделей.

Amazon Web Services (AWS) є однією з найпотужніших хмарних платформ для розгортання систем машинного навчання у промислових масштабах. Ключовим інструментом є Amazon SageMaker, який надає повноцінне середовище для створення, навчання, оцінки та впровадження моделей штучного інтелекту. AWS дозволяє обирати конфігурацію апаратних ресурсів (типи процесорів, GPU, обсяг оперативної пам'яті), зберігати великі обсяги даних у сервісі Amazon S3, а також реалізовувати контейнеризацію через Docker. Серед значних переваг AWS — стабільність, масштабованість і гнучка система керування ресурсами. Ці можливості роблять його доцільним вибором для комерційних проєктів і великих дослідницьких систем. Основним недоліком є вартість використання, яка може бути значною при тривалому навчанні нейронних мереж або використанні потужних GPU [19].

Microsoft Azure Machine Learning (Azure ML) — це гнучка платформа для створення, навчання та розгортання моделей штучного інтелекту [20]. Її особливістю є можливість візуального проектування конвеєрів машинного навчання, що дозволяє користувачам без глибоких знань програмування налаштовувати процеси оброблення даних, навчання моделей і оцінки результатів. Azure ML підтримує роботу з TensorFlow, PyTorch і Scikit-learn, а також має інтеграцію з іншими сервісами Microsoft, такими як Power BI та Azure Data Lake. Платформа забезпечує можливість використання GPU, автоматичного підбору гіперпараметрів (AutoML) і відстеження експериментів.

Вона підходить для корпоративних і дослідницьких задач, де важлива надійність, безпека даних і масштабованість.

IBM Watson Studio — це потужна інтегрована платформа для роботи з даними, аналітикою та машинним навчанням. Вона орієнтована на спільну роботу команд розробників, аналітиків і дослідників у межах одного середовища. Watson Studio підтримує Python, R і Scala, а також інтегрується з TensorFlow, PyTorch і Keras. Однією з ключових функцій є автоматизація процесів розроблення моделей (AutoAI), яка дозволяє підібрати оптимальні архітектури та параметри без ручного втручання. Платформа також пропонує інструменти для побудови візуальних звітів, роботи з великими наборами даних і відстеження продуктивності моделей. Watson Studio часто використовується у бізнесі для побудови аналітичних систем і розумних сервісів [21].

Anaconda є популярним дистрибутивом Python, який включає більшість необхідних бібліотек для аналізу даних, машинного навчання та візуалізації. У поєднанні з Jupyter Notebook це середовище є зручним інструментом для локального розроблення, відлагодження коду, підготовки даних і побудови прототипів моделей. Anaconda має власний менеджер пакетів (conda), що дозволяє створювати ізольовані середовища для різних проектів, уникаючи конфліктів залежностей. Основними перевагами є стабільність, простота встановлення, офлайн-доступ і підтримка більшості наукових бібліотек (NumPy, Pandas, Matplotlib, TensorFlow, Keras тощо) [22]. Недоліком є відсутність безкоштовного доступу до потужних GPU, тому Anaconda зазвичай використовується для початкового етапу дослідження, обробки даних і тестування невеликих моделей.

Kaggle — це не просто платформа для проведення змагань з машинного навчання, а повноцінне середовище для досліджень, розробки та обміну знаннями. У сфері класифікації зображень овочів і фруктів Kaggle відіграє особливу роль завдяки поєднанню кількох ключових можливостей: доступу до

відкритих наборів даних, інтегрованих обчислювальних ресурсів та активної спільноти дослідників [23].

На відміну від традиційних середовищ розробки, Kaggle надає користувачам готові Jupyter-подібні ноутбуки, де можна одночасно писати код, описувати методику та візуалізувати результати. Це робить дослідження прозорими й відтворюваними, адже будь-який користувач може скопіювати чужий проект і адаптувати його під власні дані. Для задач класифікації фруктів і овочів це особливо цінно, адже дозволяє швидко тестувати нові архітектури CNN чи стратегії аугментації зображень.

Навчання моделей глибокого навчання, особливо CNN, є обчислювально складним процесом. Kaggle вирішує цю проблему, надаючи безкоштовний доступ до графічних процесорів (GPU) та тензорних процесорів (TPU). Це робить платформу доступною навіть для тих дослідників, які не мають власного обладнання (рис. 2.1).

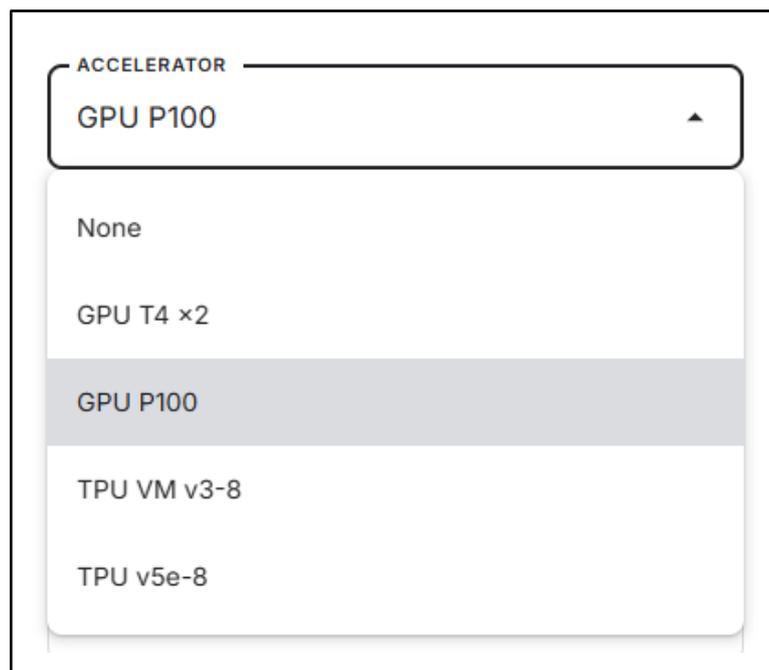


Рисунок 2.1 – Використання графічних та тензорних процесорів на Kaggle [24]

Завдяки GPU/TPU можна навчати складні моделі за години, а не за дні. Це особливо важливо для задач класифікації зображень фруктів і овочів у сфері зберігання, де потрібно швидко протестувати кілька варіантів архітектур, перш ніж інтегрувати модель у виробничу систему. Дослідження показують, що використання Kaggle як навчального середовища дозволяє зменшити час на експерименти на 30–40% у порівнянні з локальними машинами без GPU .

Ще однією сильною стороною Kaggle є активна міжнародна спільнота. Тут можна знайти тисячі прикладів готових рішень, від простих CNN до складних ансамблів моделей. Для дослідників, які працюють над класифікацією овочів і фруктів, це означає доступ до практичного досвіду колег, можливість обговорювати результати та вдосконалювати власні підходи.

З огляду на вимоги проекту, основним середовищем розроблення було обрано Kaggle Notebooks, яке забезпечує оптимальний баланс між зручністю використання, обчислювальною потужністю та доступністю.

### **2.3 Вибір датасету для тренування та тестування моделей**

Одним із ключових етапів побудови системи класифікації зображень є вибір і підготовка навчальних даних. Якість та збалансованість вибраного набору зображень безпосередньо впливають на точність, узагальнювальну здатність і стабільність роботи моделі. Для задач класифікації фруктів і овочів доцільно використовувати відкриті датасети, які містять велику кількість зображень різних класів і дозволяють ефективно навчати моделі глибокого навчання.

Однією з найбільших переваг Kaggle є доступ до різноманітних відкритих датасетів. У розділі Datasets можна знайти кілька великих збірок, присвячених саме фруктам і овочам. Наприклад, набір Fruits 360 Dataset є одним із найвідоміших і наймасштабніших датасетів для класифікації фруктів та овочів (рис. 2.2). Він містить понад 140 000 зображень 210 різних класів, включаючи

різні сорти яблук, бананів, апельсинів, а також рідкісні тропічні фрукти, овочі та горіхи - всього 3,83 ГБ зображень, які стандартизовані за розміром (100x100 пікселів), що спрощує їхню обробку [25].

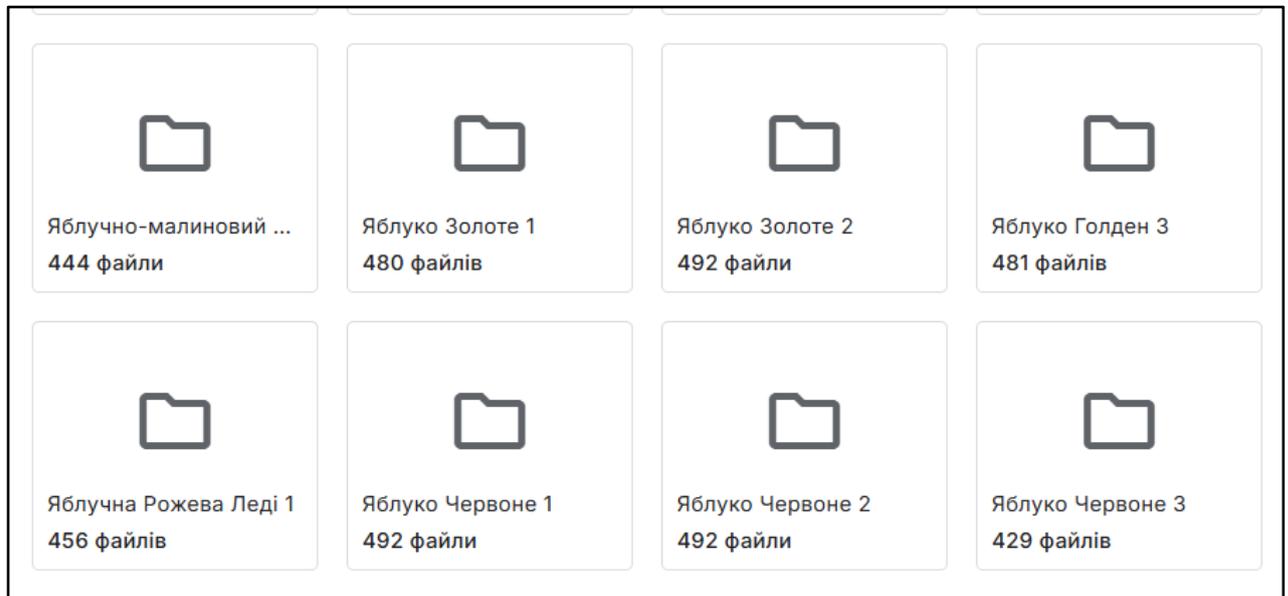


Рисунок 2.2 – Частина каталогу Fruits 360 Dataset з зображеннями яблук

Датасет Fruit and Vegetable Disease (Healthy vs Rotten) створено з метою забезпечення якісної бази для розробки автоматизованих систем, здатних ефективно розрізняти здорові овочі та фрукти від зіпсованих, пошкоджених або уражених хворобами. Такий набір даних є важливим інструментом для формування моделей машинного та глибокого навчання, орієнтованих на підвищення точності контролю якості продукції, автоматизацію процесів сортування, а також мінімізацію втрат у харчовому ланцюгу.

До складу датасету входять зображення 14 різних видів плодоовочевої продукції, що дозволяє охопити досить широкий спектр форм, кольорів і текстур. Кожен вид представлений у двох основних категоріях: "Healthy" (здоровий) та "Rotten" (зіпсований). Поділ на такі класи дає змогу моделі вчитись аналізувати характерні візуальні ознаки псування — зміни кольору, наявність плям, ураження грибками, деформації або інші дефекти поверхні.

Структура датасету є інформативною та зручною для побудови моделей глибокого навчання, оскільки забезпечує достатню різноманітність прикладів для кожної категорії. Вона також сприяє більш якісному навчанню алгоритмів, які мають працювати в умовах реального середовища, де плоди можуть відрізнятися за ступенем стиглості, розмірами чи умовами освітлення. Як показано на рисунку 2.3.



Рисунок 2.3 – Здорові та гнілі зображення бананів [26]

Датасет Fresh and Stale Images of Fruits and Vegetables [27] схожий на попередній. Цей набір даних фокусується на розпізнаванні свіжих та несвіжих продуктів (більше 14,7 тис. файлів у форматах .png та .jpg). Його було зібрано за допомогою камер мобільних телефонів, що робить його особливо корисним для розробки мобільних додатків (рис. 2.4).

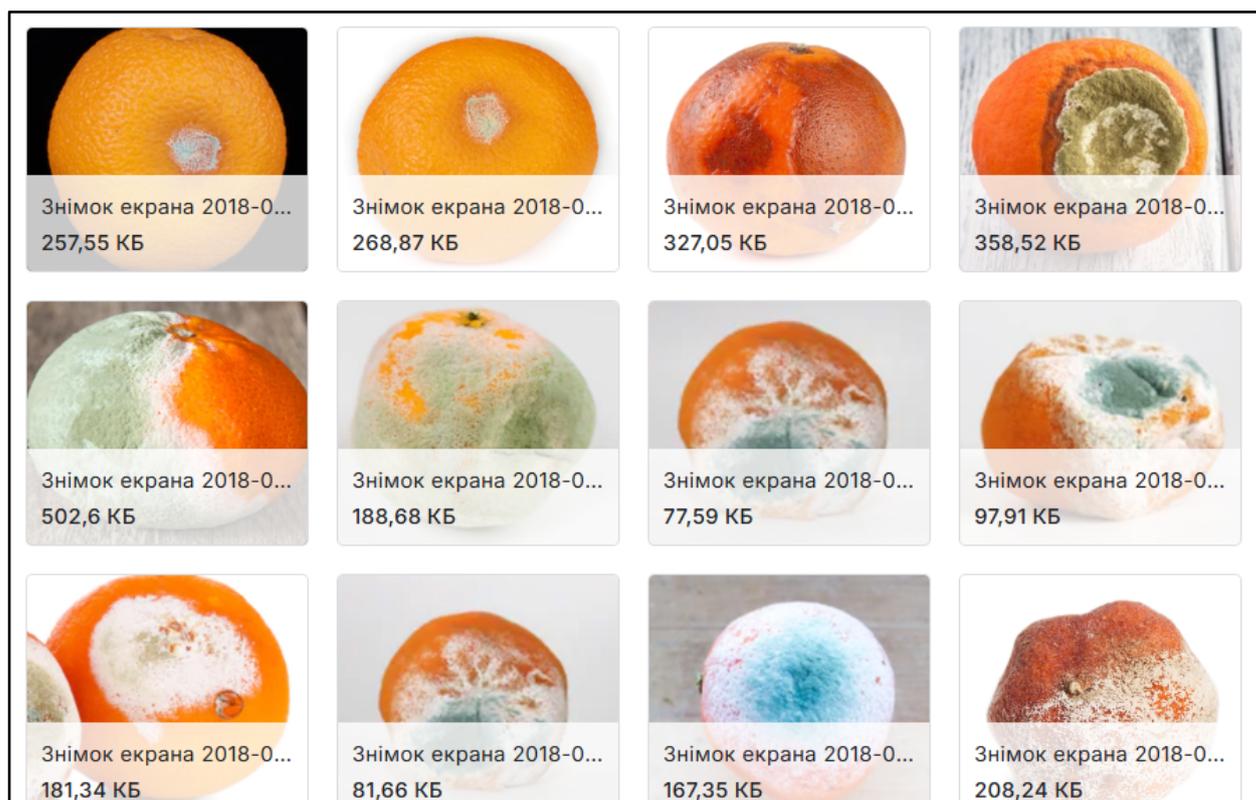


Рисунок 2.4 – Фрагмент датасету зіпсованих фруктів [27]

Однак для проведення експериментів у межах даної роботи було обрано саме Fruits and Vegetables Image Recognition Dataset [28], який також доступний на платформі Kaggle (рис. 2.5). Основною причиною вибору цього набору є оптимальне співвідношення між кількістю зображень, якістю даних і швидкістю обробки. На відміну від великих датасетів, таких як Fruits 360, даний набір містить помірну кількість зображень — кілька тисяч екземплярів різних категорій фруктів і овочів, що дозволяє швидко проводити навчання навіть на обмежених обчислювальних ресурсах.

Крім того, цей датасет характеризується різноманітністю кутів зйомки, умов освітлення та типів фону, що забезпечує кращу узагальнювальну здатність моделі.

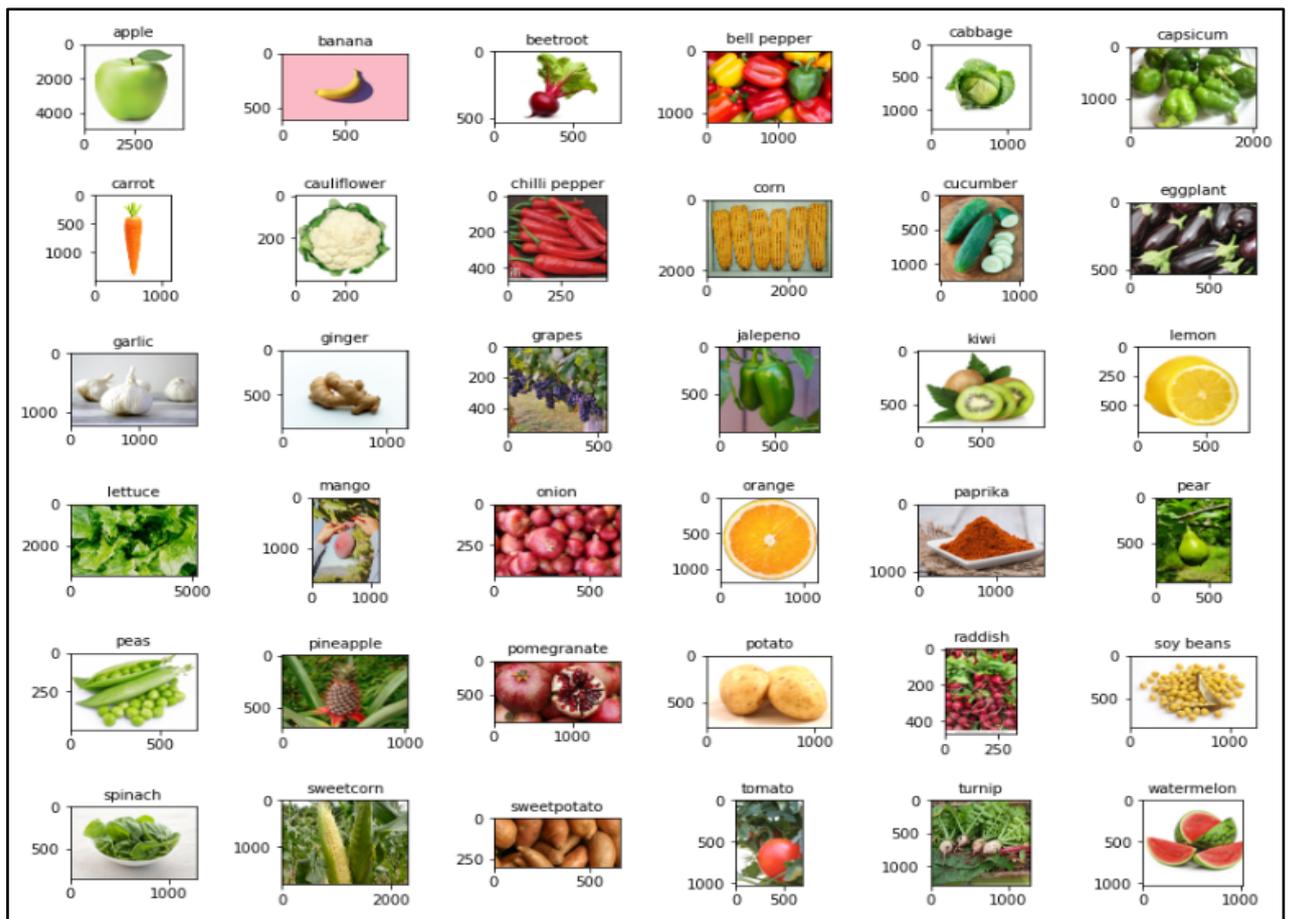


Рисунок 2.5 – Фрагмент датасету Fruits and Vegetables Image Recognition [24]

Зображення мають достатньо високу якість (роздільну здатність), що дозволяє моделі ефективно виділяти ключові ознаки об'єктів (текстуру, форму, колір). Усі зображення структуровано за 36 класами, що полегшує процес імпорту та підготовки вибірки до навчання.

## 2.4 Висновки

У цьому розділі було обґрунтовано вибір мови програмування, бібліотек, середовища розроблення та набору даних для створення системи класифікації зображень овочів і фруктів. Найбільш ефективним рішенням виявився Python, який завдяки широкому набору бібліотек (TensorFlow, Keras, OpenCV, NumPy,

Pandas) забезпечує зручну роботу з візуальними даними, можливість глибокого навчання та інтеграцію з іншими аналітичними інструментами.

Середовищем розроблення визначено Kaggle Notebooks. Його обрано через зручний інтерфейс, безкоштовний доступ до GPU, готові інструменти для аналізу та можливість швидкого тестування різних архітектур, що робить його оптимальним порівняно з Google Colab чи AWS SageMaker.

Для навчання моделей використано датасет “Fruits and Vegetables Image Recognition Dataset”, що забезпечує необхідний баланс між кількістю, якістю та різноманітністю зображень.

Створені передумови дозволяють перейти до наступних етапів: розвідувального аналізу даних, побудови та навчання моделей, оцінювання їх ефективності та визначення практичних можливостей застосування класифікації для контролю стану овочевої продукції.

## 3 РОЗРОБЛЕННЯ ІНФОРМАЦІЙНОЇ ІНТЕЛЕКТУАЛЬНОЇ ТЕХНОЛОГІЇ КЛАСИФІКАЦІЇ ЗОБРАЖЕНЬ ОВОЧІВ ТА ФРУКТІВ

### 3.1 Розвідувальний аналіз даних

Датасет Fruits and Vegetables Image Recognition використовується для класифікації зображень фруктів та овочів [28]. Набір даних містить зображення різних фруктів та овочів, що забезпечує різноманітну колекцію для задач класифікації зображень.

До нього входять такі продукти харчування. Фрукти: Банан, яблуко, груша, виноград, апельсин, ківі, кавун, гранат, ананас, манго. Овочі: Огірок, морква, стручковий перець, цибуля, картопля, лимон, помідор, редиска, буряк, капуста, салат, шпинат, соя, цвітна капуста, болгарський перець, перець чилі, ріпа, кукурудза, солодка кукурудза, батат, паприка, халапеньо, імбир, часник, горох, баклажани [24]. Зображення мають різну роздільну здатність, але більшість з них є кольоровими (RGB). Якість зображень варіюється, що відображає реальні умови фотографування. Фон на зображеннях також різноманітний – від однорідного до природного середовища, що робить задачу класифікації більш складною та реалістичною. Набір даних включає різні варіації всередині одного класу, такі як різні сорти, ракурси та умови освітлення.

Як видно на рисунку Г.4, зображення мають різну форму, що може бути складним завданням для нашої моделі.

Цей набір даних містить три папки: навчальна (близько 100 зображень у кожній) тестова (близько 10 зображень у кожній) перевірна (близько 10 зображень у кожній), кожна з вищезазначених папок містить підпапки для різних фруктів та овочів, в яких містяться зображення відповідних продуктів харчування (рис. 3.1).

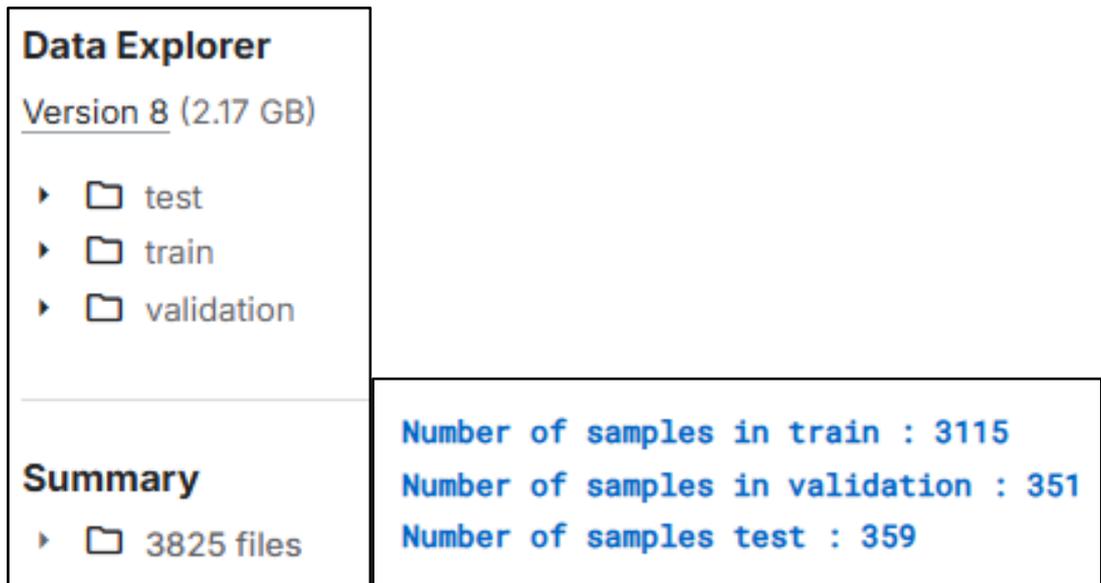


Рисунок 3.1 – Структура датасету Fruits and Vegetables Image Recognition [28]

Як видно з графіка на рисунку 3.2 деякі категорії зображень мають 100 зразків, що вказує на баланс у вибірці, однак є мітки з нижчою кількістю (наприклад, 61, 63, 68), що свідчить про дисбаланс у даних [24].

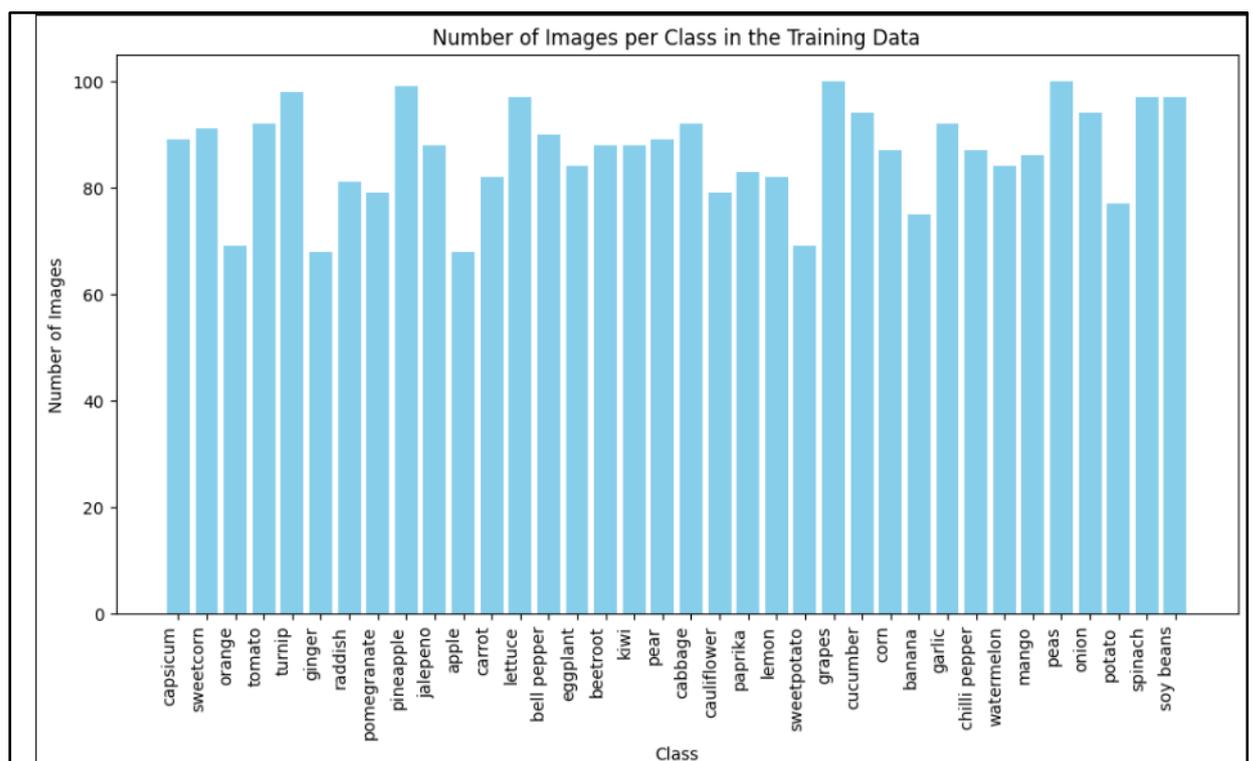


Рисунок 3.2 – Візуалізація розподілу класів у тренувальному наборі даних [24]

Тестові дані є більш збалансовані (рис. 3.3)

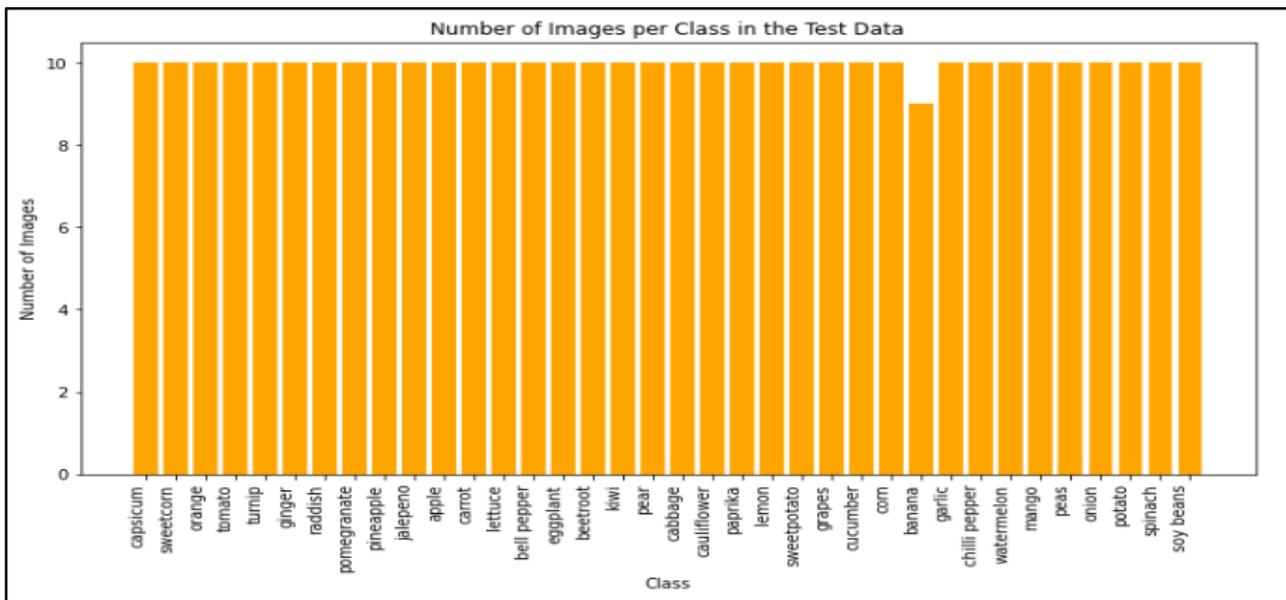


Рисунок 3.3 – Візуалізація розподілу класів у тестовому наборі даних [24]

Дані валідації є теж добре збалансованим (рис. 3.4).

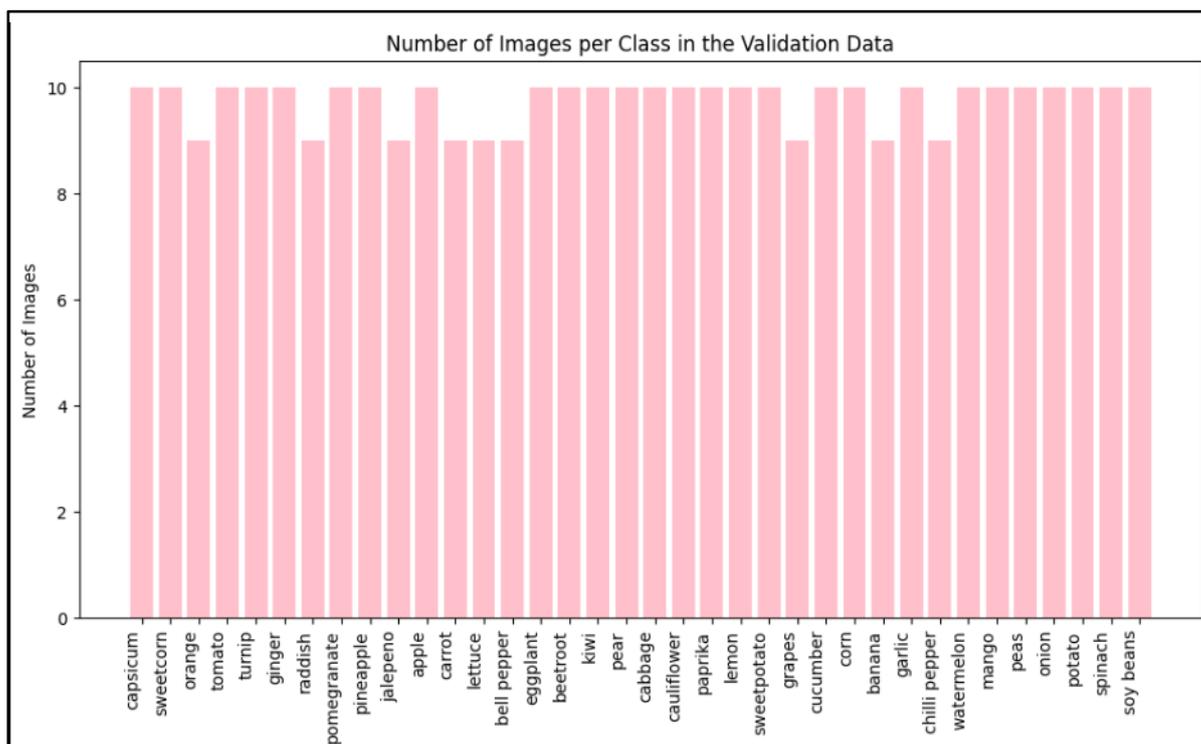


Рисунок 3.4 – Візуалізація розподілу класів у валідаційному наборі даних [24]

Як видно з рисунка 3.5 на зображеннях об'єкти кожного класу представлено в різних ракурсах, що ускладнює їх ототожнення.



Рисунок 3.5 – Фрагмент папки orange (69 files) [29]

### 3.2 Передоброблення даних

Для моделей Keras Sequential та EfficientNetB0 усі вхідні зображення були попередньо оброблені шляхом приведення їх до стандартного розміру  $224 \times 224$  пікселів, що відповідає вимогам більшості сучасних архітектур глибокого навчання. Після масштабування виконано нормалізацію значень пікселів — перетворення діапазону інтенсивностей із  $[0,255]$  у  $[0,1]$ . Така нормалізація зменшує розкид значень і сприяє швидшій та стабільнішій збіжності моделі під час навчання, що показано на рисунку 3.6.



Рисунок 3.6 – Зображення фруктів та овочів, приведені до одного розміру

Дані були структуровані у міні-пакети (batches) по 32 зображення. Використання саме такого розміру пакета є оптимальним компромісом між швидкістю обчислень та стабільністю оновлення ваг моделі. Завдяки пакетній обробці зменшується споживання пам'яті та підвищується пропускна здатність під час тренування, а навчальний процес ефективно масштабується як на GPU, так і на CPU.

Крім того, поділ даних на пакети забезпечує можливість рівномірного перемішування (shuffling) зображень між епохами, що зменшує ризик перенавчання та сприяє кращій узагальнювальній здатності моделі. У результаті така організація даних створює оптимальні умови для ефективного тренування як базової моделі Keras Sequential, так і більш складної EfficientNetB0, що має значно більшу кількість параметрів.

Для моделі MobileNetV2 було застосовано інший підхід. Дані спочатку перетворювалися на датафрейми, які містили шляхи до зображень і відповідні мітки класів. Це дозволяло застосовувати більш гнучкі стратегії попередньої обробки та аугментації. Створення таких датафреймів виконувалося за допомогою спеціальної функції, яка обходила всі підпапки з класами (рис. 3.7).

```
def create_df(folder_path) :
    all_images = []
    for class_name in classes :
        class_path = os.path.join(folder_path, class_name)
        all_images.extend([(os.path.join(class_path, file_name), class_name) for file_name in os.listdir(class_path)])
    df = pd.DataFrame(all_images, columns=['file_path', 'label'])
    return df
train_df = create_df(train_path)
validation_df = create_df(validation_path)
test_df = create_df(test_path)
```

Рисунок 3.7 – Генерація DataFrame [24]

Для подальшої генерації батчів даних використовувалися об'єкти ImageDataGenerator, які забезпечують динамічне завантаження та обробку зображень під час навчання моделі. Для навчальної вибірки було налаштовано розширений набір аугментацій, що включав обертання зображень, горизонтальні віддзеркалення, масштабування, повороти, зсуви вздовж осей, а також зсув зрізу (shear transformation). Завдяки цим перетворенням штучно збільшувалася різноманітність навчального набору, моделювалися реальні варіації у зображеннях фруктів та овочів і значно знижувався ризик перенавчання моделі.

Такі операції дозволяють зробити модель більш стійкою до змін освітлення, положення, орієнтації та часткового перекриття об'єктів, що є важливим фактором у практичних сценаріях, особливо при роботі з даними, зібраними в польових умовах або на конвеєрних лініях.

Також підвищується здатність моделі до узагальнення та зменшує ризик перенавчання (overfitting). Це наочно продемонстровано на відповідному рисунку 3.8.

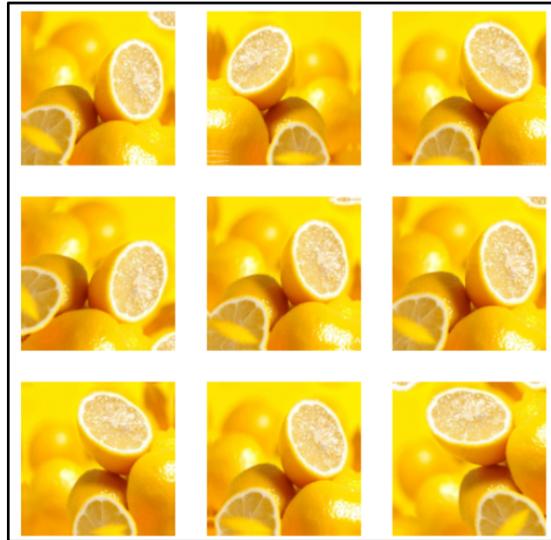


Рисунок 3.8 – Аугментація навчальних даних

Для валідаційної та тестової вибірок застосовувалася лише базова нормалізація — масштабування значень пікселів у діапазон  $[0, 1]$ , без додаткових перетворень. Це гарантувало чесність оцінювання та відповідність умов тестування реальним даним, які не піддаються штучним змінам. Відповідний код процесу показано на рисунку 3.9.

```

train_datagen = ImageDataGenerator(
    rescale=1./255,
    rotation_range=20,
    width_shift_range=0.2,
    height_shift_range=0.2,
    zoom_range=0.1,
    horizontal_flip=True,
    shear_range=0.1,
    fill_mode='nearest'
)

train_generator = train_datagen.flow_from_dataframe(
    dataframe=train_df,
    x_col='file_path',
    y_col='label',
    target_size=(224, 224),
    color_mode='rgb',
    class_mode='categorical',
    batch_size=32,
    shuffle=True,
    seed=42
)

```

Рисунок 3.9 – Аугментація та підготовка зображень для тренування моделі [24]

Таким чином, для моделей Keras Sequential та EfficientNetB0 використовувався стандартний підхід на основі `image_dataset_from_directory`, тоді як для MobileNetV2 було реалізовано більш гнучке зчитування зображень через датафрейми і генератори зображень з вбудованою аугментацією. Такий підхід забезпечив відповідність формату даних вимогам обраних архітектур і дозволив підвищити узагальнювальну здатність моделей.

### 3.3 Створення алгоритму побудови та дослідження моделей

На рисунку Г.1 наведено блок-схему алгоритму, що був використаний у подальшій роботі для реалізації процесу класифікації зображень овочів і фруктів. Запропонований алгоритм відображає повний та завершений цикл побудови моделі — від початкового завантаження сирих даних до вибору найефективнішого варіанту моделі на основі отриманих експериментальних результатів. Така структурована послідовність дій відіграє важливу роль, оскільки забезпечує логічність виконання кроків, узгодженість між етапами та можливість повторення експериментів у майбутньому, що є ключовим аспектом будь-якого наукового дослідження у сфері машинного навчання.

Алгоритм включає такі ключові етапи:

- Імпорт бібліотек. На цьому етапі підключається все необхідне програмне забезпечення для роботи з даними: бібліотеки для маніпулювання масивами та таблицями, інструменти для автоматизованої обробки зображень, фреймворки для побудови та навчання нейронних мереж, а також пакети для візуалізації й аналізу результатів. Правильний вибір і коректне підключення бібліотек є фундаментом успішної реалізації всього проєкту.

- Імпорт датасету. На цьому кроці здійснюється завантаження зображень овочів і фруктів, які поділено на навчальну, валідаційну та тестову вибірки. Дані групуються за класами, що дозволяє моделі вивчати особливості кожної

категорії. Додатково проводиться первинна перевірка структури директорій, кількості прикладів у кожному класі та коректності форматів файлів.

– Розвідувальний аналіз даних (EDA). Цей етап є надзвичайно важливим для розуміння природи даних: виконується аналіз розподілу класів, візуалізація прикладів, оцінка їх різноманітності, якості та чіткості. Проводиться пошук потенційних проблем, як-от дублікати зображень, нерівномірний розподіл даних між класами, сильні відмінності у масштабах або освітленні. Такий аналіз дозволяє заздалегідь визначити виклики, які можуть вплинути на точність моделі.

– Передоброблення даних. Включає масштабування та нормалізацію зображень, їх аугментацію (повороти, зсуви, віддзеркалення тощо), стандартизацію розмірів та інші перетворення. Правильна передобробка підвищує якість даних, сприяє більш стабільному навчанню моделі та зменшує ризики перенавчання. На цьому етапі також визначається оптимальний формат подання зображень у модель.

– Побудова моделі класифікації. Формується архітектура нейронної мережі — як власноруч створена (Custom CNN), так і заснована на попередньо навчальних моделях (MobileNetV2, EfficientNetB0 тощо). Вибираються функції активації, оптимізатори, параметри регуляризації, кількість шарів і нейронів.

– Тренування моделі. На цьому етапі модель вчиться визначати взаємозв'язки між ознаками на зображеннях та їх належністю до певного класу. Проводиться аналіз точності та функції втрат на тренувальних і валідаційних даних, відстежується динаміка навчання, визначається, чи потребує модель додаткової оптимізації.

– Оцінювання результатів класифікації. Після завершення навчання виконується глибокий аналіз результатів: побудова графіків точності та втрат, оцінка матриці змішувань, визначення сильних та слабких сторін моделі. Це дозволяє виявити, які саме класи модель розпізнає найкраще, а де можуть виникати помилки.

– Коригування параметрів у разі незадовільних результатів. Якщо модель демонструє низьку точність або високий рівень втрат, проводиться уточнення параметрів: зміна швидкості навчання, додавання нових шарів, корекція набору аугментацій, балансування вибірки тощо. Алгоритм передбачає повернення до попередніх етапів, що робить процес гнучким і придатним для поетапного вдосконалення.

– Класифікація тестового набору даних. Коли модель досягає прийнятної рівня точності, її перевіряють на тестових зображеннях, які модель раніше ніколи не бачила. Це дозволяє оцінити реальну ефективність алгоритму в умовах, наближених до практичного застосування.

– Вибір оптимальної моделі. На фінальному етапі здійснюється порівняння всіх отриманих результатів та визначається той варіант моделі, який забезпечує найкращий баланс між точністю, стабільністю роботи та швидкістю класифікації.

Дотримання цього алгоритму забезпечує системний та надійний підхід до створення моделі глибокого навчання, що дозволяє ефективно виконати поставлену задачу та забезпечити відтворюваність результатів у майбутніх дослідженнях.

### **3.4 Побудова, оцінка результатів та вибір оптимальної моделі**

На основі результатів оцінки на тестовому наборі та враховуючи вимоги до задачі (баланс між точністю та швидкістю), обирається найкраща модель. Аналізуються сильні та слабкі сторони обраної моделі в порівнянні з її аналогом.

### 3.4.1 Побудова та результати роботи моделі Custom CNN

Модель являє собою згорткову нейронну мережу (CNN), розроблену для завдання класифікації зображень за допомогою бібліотеки Keras. Вона складається з кількох шарів, які послідовно обробляють вхідні дані, як це показано на рисунку 3.10.

| Layer (type)  | Output Shape         | Param # |
|---|----------------------|---------|
| conv2d_3 (Conv2D)                                   | (None, 224, 224, 32) | 896     |
| batch_normalization_4 (BatchNormalization)          | (None, 224, 224, 32) | 128     |
| max_pooling2d_3 (MaxPooling2D)                      | (None, 112, 112, 32) | 0       |
| conv2d_4 (Conv2D)                                   | (None, 112, 112, 64) | 18,496  |
| batch_normalization_5 (BatchNormalization)          | (None, 112, 112, 64) | 256     |
| max_pooling2d_4 (MaxPooling2D)                      | (None, 56, 56, 64)   | 0       |
| conv2d_5 (Conv2D)                                   | (None, 56, 56, 128)  | 73,856  |
| batch_normalization_6 (BatchNormalization)          | (None, 56, 56, 128)  | 512     |
| max_pooling2d_5 (MaxPooling2D)                      | (None, 28, 28, 128)  | 0       |
| dropout_2 (Dropout)                                 | (None, 28, 28, 128)  | 0       |
| global_average_pooling2d_1 (GlobalAveragePooling2D) | (None, 128)          | 0       |
| dense_2 (Dense)                                     | (None, 256)          | 33,024  |
| batch_normalization_7 (BatchNormalization)          | (None, 256)          | 1,024   |
| dropout_3 (Dropout)                                 | (None, 256)          | 0       |
| dense_3 (Dense)                                     | (None, 36)           | 9,252   |

Total params: 137,444 (536.89 KB)  
 Trainable params: 136,484 (533.14 KB)  
 Non-trainable params: 960 (3.75 KB)

Рисунок 3.10 – Архітектура нейронної мережі моделі Custom CNN

Витягування ознак.

Модель послідовно застосовує шари Conv2D із кількістю фільтрів 32, 64 і 128, щоб поступово виявляти ознаки різної складності на зображенні. Функція активації ReLU допомагає моделі краще розпізнавати складні залежності, а шар MaxPooling2D зменшує розмір зображення та робить модель стійкішою до змін ракурсу. На рисунку 3.11 представлено приклад візуалізації областей уваги нейронної мережі, де яскраві червоні ділянки вказують на пікселі з найбільшим внеском у кінцеве рішення класифікатора.

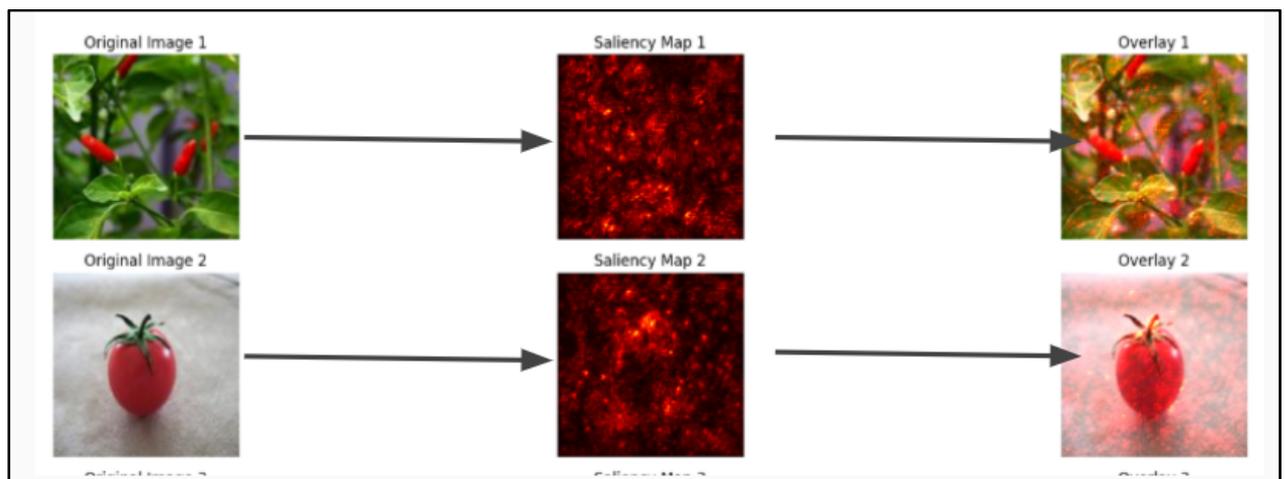


Рисунок 3.11 – Приклади карт важливості пікселів (Saliency Maps) для зображень перцю та томату

Регуляризація: для запобігання перенавчанню застосовуються BatchNormalization, Dropout (0.3; 0.4) та L2-регуляризація, що сприяють узагальненню моделі.

Класифікація етап. Після GlobalAveragePooling2D формується вектор ознак, який обробляють Dense-шари. Завершальний Dense (36 нейронів) із функцією активації Softmax визначає ймовірність належності зображення до кожного класу.

Для аналізу рішень моделі були згенеровані теплові карти активацій. Кольори теплової карти — це візуальне представлення інтенсивності активацій:

у ківі червоно-жовта зона — на м'якоті, тобто саме там модель «бачить» ключові ознаки, у кукурудзи — на зернах качана, бо вони мають характерну текстуру й колір (рис. 3.12).

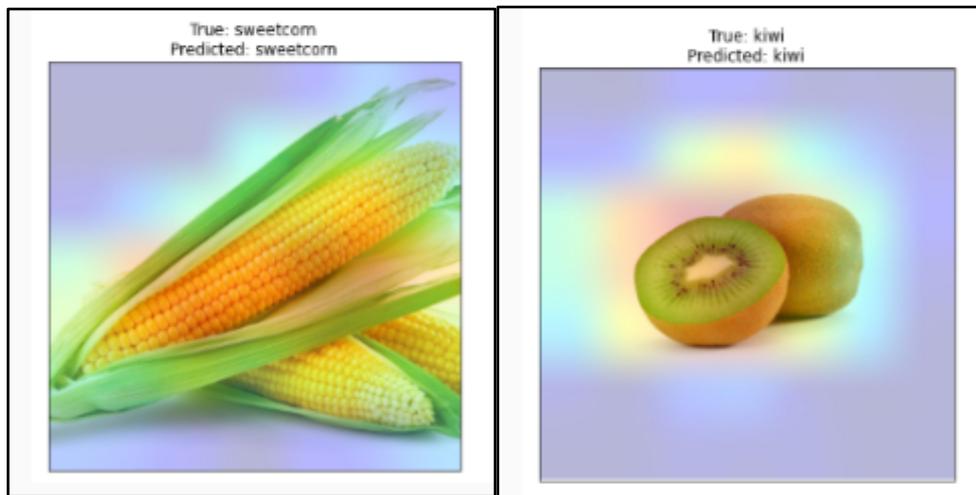
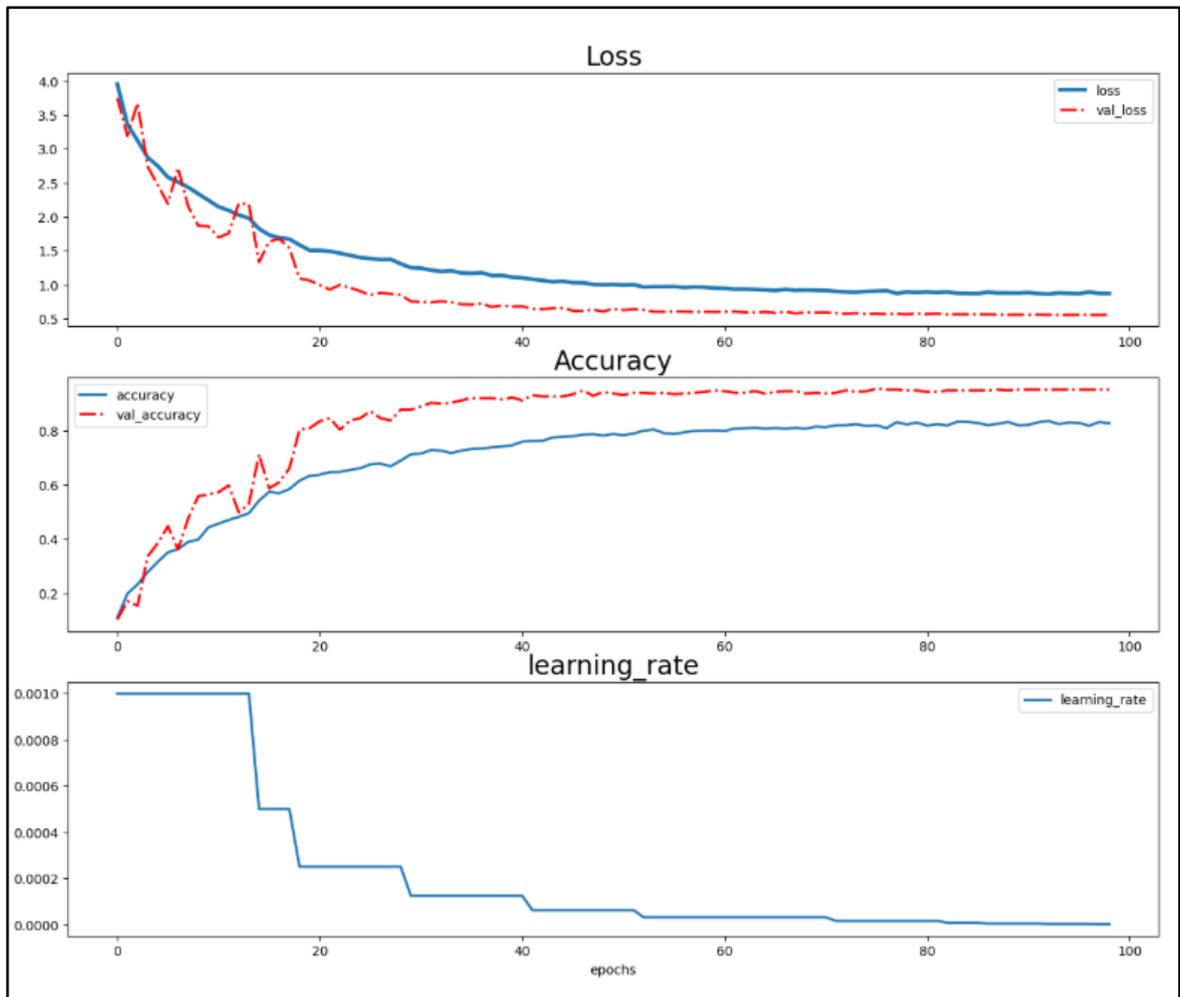


Рисунок 3.12 – Ідентифікація ключових ознак (м'якоті та зерен) за допомогою теплових карт.

Модель Custom CNN демонструє доволі високий рівень ефективності у задачі класифікації зображень овочів та фруктів, що свідчить про її здатність якісно виявляти та розрізняти характерні ознаки об'єктів. Високі показники точності як на тренувальному, так і на валідаційному наборі даних підтверджують, що модель не лише добре навчається на доступному датасеті, а й успішно узагальнює інформацію на раніше невидимих прикладах.

У процесі навчання спостерігається стабільна динаміка: значення функції втрат поступово зменшуються, а точність класифікації зростає з кожною епохою. Така поведінка є типовою для моделей, які добре налаштовані та отримують достатню кількість інформативних зразків для навчання. Це свідчить про те, що мережа ефективно засвоює візуальні патерни, знаходить стійкі зв'язки у даних та коректно адаптує свої параметри.

Графіки на рисунку 3.13 наочно демонструють ці процеси — криві втрат та точності плавно прямують у потрібному напрямі, не показуючи стрибків або різких коливань, що могло б вказувати на проблеми з перенавчанням чи нестачею даних. Така поведінка підтверджує стабільність процесу навчання та загальну надійність побудованої моделі.



```
Best train accuracy: 0.8363 epoch 93
Best val accuracy:  0.9544 epoch 76
Best train loss:    0.8601 epoch 93
Best val loss:     0.5530 epoch 94
```

Рисунок 3.13 – Результати тренувань моделі Custom CNN [24]

Початкові значення втрат були досить високими (понад 3.5), але вже в перші 20 епох вони швидко знизилися до  $\sim 1.0$ . Надалі втрати стабілізувалися після 60–70 епох, досягнувши мінімумів: 0.8601 для тренувальних (93-тя епоха) та 0.5530 для валідаційних (94-та епоха).

Точність зростала аналогічно: від початкових  $\sim 0.15$  до максимумів 0.8363 (тренувальна, 93-тя епоха) та 0.9544 (валідаційна, 76-та епоха). Примітно, що валідаційна точність перевищувала тренувальну з середини навчання, що свідчить про ефективну регуляризацию та хорошу здатність до узагальнення.

Швидкість навчання залишалася стабільною на початку, але знижувалася після 10–15 епох, допомагаючи уникнути перенавчання та стабілізувати оптимізацію. Загалом модель Custom CNN показала впевнене, рівномірне навчання з високими фінальними показниками якості.

Нижче у таблиці 3.1 представлені результати роботи моделі Custom CNN на тестових даних [24].

Таблиця 3.1 – Classification report роботи моделі Custom CNN

| Item         | Precision | Recall | F1-Score | Support |
|--------------|-----------|--------|----------|---------|
| orange       | 1.0       | 0.9    | 0.95     | 10      |
| paprika      | 1.0       | 0.9    | 0.95     | 10      |
| pear         | 1.0       | 1.0    | 1.0      | 10      |
| peas         | 1.0       | 1.0    | 1.0      | 10      |
| pineapple    | 1.0       | 1.0    | 1.0      | 10      |
| pomegranate  | 1.0       | 1.0    | 1.0      | 10      |
| potato       | 1.0       | 0.7    | 0.82     | 10      |
| raddish      | 1.0       | 1.0    | 1.0      | 10      |
| soy beans    | 1.0       | 1.0    | 1.0      | 10      |
| spinach      | 1.0       | 1.0    | 1.0      | 10      |
| sweetcorn    | 0.75      | 0.9    | 0.82     | 10      |
| sweetpotato  | 1.0       | 1.0    | 1.0      | 10      |
| tomato       | 1.0       | 1.0    | 1.0      | 10      |
| turnip       | 0.91      | 1.0    | 0.95     | 10      |
| watermelon   | 1.0       | 1.0    | 1.0      | 10      |
| accuracy     |           |        | 0.95     | 359     |
| macro avg    | 0.96      | 0.95   | 0.95     | 359     |
| weighted avg | 0.96      | 0.95   | 0.95     | 359     |

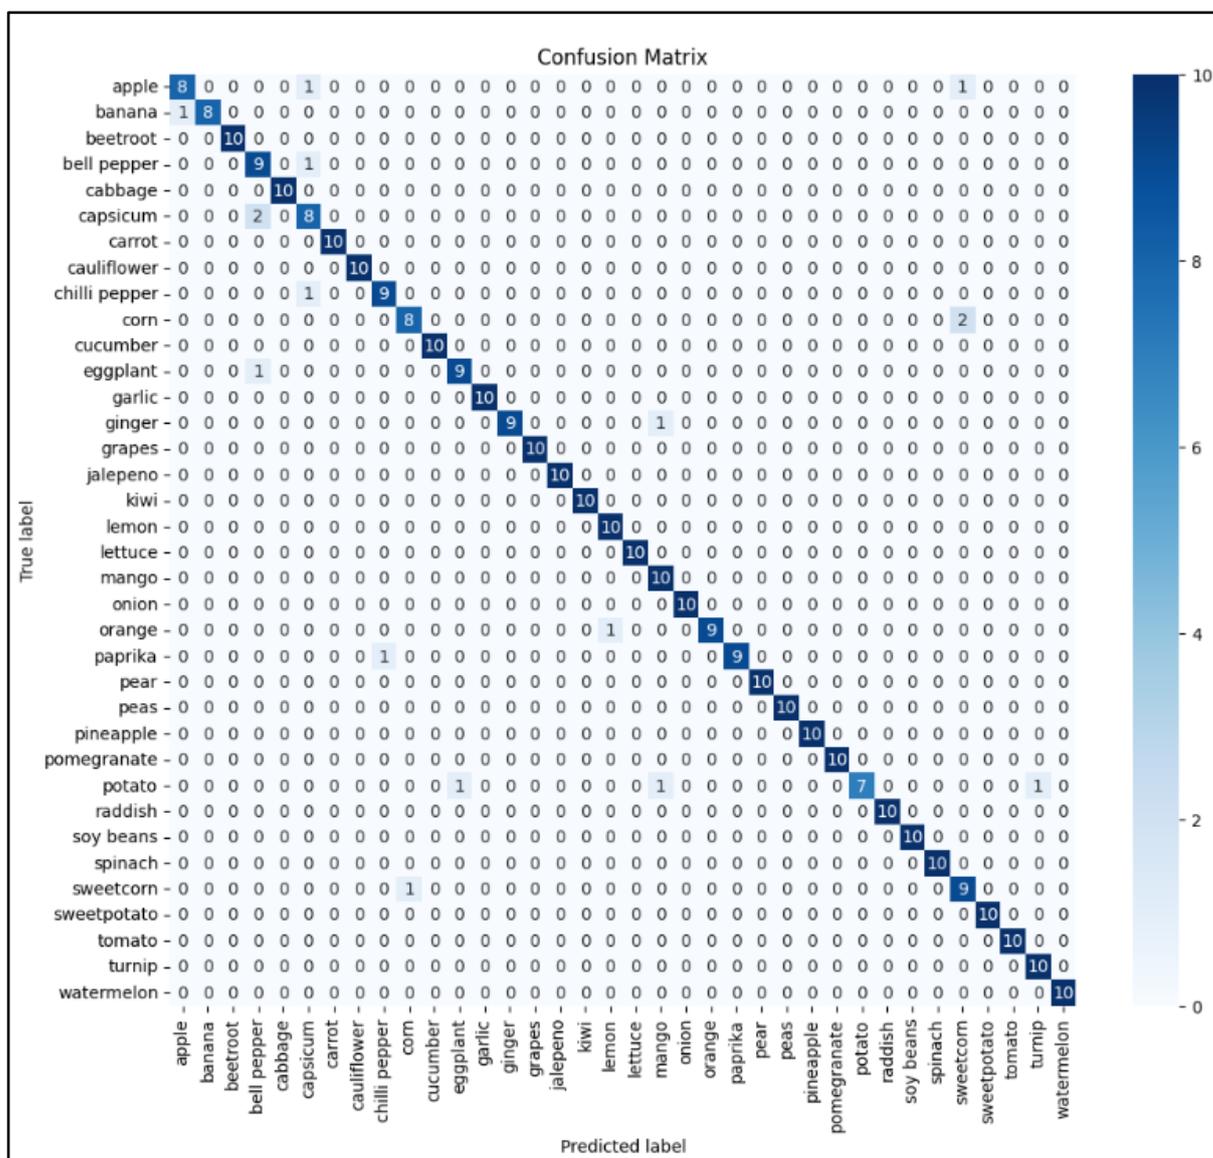
Продовження таблиці 3.1.

| Item          | Precision | Recall | F1-Score | Support |
|---------------|-----------|--------|----------|---------|
| apple         | 0.89      | 0.8    | 0.84     | 10      |
| banana        | 1.0       | 0.89   | 0.94     | 9       |
| beetroot      | 1.0       | 1.0    | 1.0      | 10      |
| bell pepper   | 0.75      | 0.9    | 0.82     | 10      |
| cabbage       | 1.0       | 1.0    | 1.0      | 10      |
| capsicum      | 0.73      | 0.8    | 0.76     | 10      |
| carrot        | 1.0       | 1.0    | 1.0      | 10      |
| cauliflower   | 1.0       | 1.0    | 1.0      | 10      |
| chilli pepper | 0.9       | 0.9    | 0.9      | 10      |
| corn          | 0.89      | 0.8    | 0.84     | 10      |
| cucumber      | 1.0       | 1.0    | 1.0      | 10      |
| eggplant      | 0.9       | 0.9    | 0.9      | 10      |
| garlic        | 1.0       | 1.0    | 1.0      | 10      |
| ginger        | 1.0       | 0.9    | 0.95     | 10      |
| grapes        | 1.0       | 1.0    | 1.0      | 10      |
| jalepeno      | 1.0       | 1.0    | 1.0      | 10      |
| kiwi          | 1.0       | 1.0    | 1.0      | 10      |
| lemon         | 0.91      | 1.0    | 0.95     | 10      |
| lettuce       | 1.0       | 1.0    | 1.0      | 10      |
| mango         | 0.83      | 1.0    | 0.91     | 10      |
| onion         | 1.0       | 1.0    | 1.0      | 10      |

Модель демонструє високу точність 0.95, а макросередні та зважені показники (0.95–0.96) підтверджують її стабільну роботу для всіх класів. Більшість категорій, зокрема beetroot, cabbage, cauliflower, garlic, grapes, kiwi, lettuce, pear, pineapple, tomato та watermelon, класифікуються безпомилково з повними значеннями всіх метрик (1.00).

Водночас окремі класи залишаються складнішими. Для potato повнота становить 0.70, що свідчить про значну кількість пропусків. Bell pepper, sweetcorn і capsicum також мають знижені показники через схожість із іншими овочами. Це свідчить про те, що візуальна подібність є ключовою причиною помилок моделі.

Конфузійна матриця підтверджує загальну надійність класифікації: більшість передбачень потрапляють на діагональ, а помилки зосереджені навколо схожих класів — наприклад, між яблуком і грушею або між різними видами перців. Загалом модель працює стабільно й демонструє високу результативність.



Test Loss: 0.5523281097412109

Test Accuracy: 0.9526462554931641

Рисунок 3.14 – Конфузійна матриця роботи моделі Custom CNN [24]

### 3.4.2 Побудова та результати роботи моделі на основі MobileNetV2

Для виконання задачі класифікації було використано попередньо натреновану модель MobileNetV2, яка вирізняється високою ефективністю, компактністю та швидкодією, що робить її зручною для роботи в системах реального часу й на пристроях з обмеженими ресурсами.

У дослідженні інтегровано модель MobileNetV2 з вагами, отриманими під час навчання на великому наборі зображень ImageNet, що містить понад 1,2 млн зразків і охоплює 1000 класів об'єктів. Завдяки такому попередньому навчанню модель уже має сформовані універсальні ознаки, що дозволяє ефективно адаптувати її до класифікації овочів і фруктів.

Поверх базової архітектури було додано власні класифікаційні шари, що забезпечило швидке й точне навчання на цільовому датасеті. Загальну структуру моделі та етапи оброблення даних наведено на рисунку 3.15.

| Layer (type)   | Output Shape       | Param #   |
|--|--------------------|-----------|
| mobilenetv2_1.00_224 (Functional)                    | (None, 7, 7, 1280) | 2,257,984 |
| global_average_pooling2d_11 (GlobalAveragePooling2D) | (None, 1280)       | 0         |
| dropout_21 (Dropout)                                 | (None, 1280)       | 0         |
| dense_24 (Dense)                                     | (None, 256)        | 327,936   |
| batch_normalization_18 (BatchNormalization)          | (None, 256)        | 1,024     |
| dropout_22 (Dropout)                                 | (None, 256)        | 0         |
| dense_25 (Dense)                                     | (None, 36)         | 9,252     |

Рисунок 3.15 – Архітектура нейронної мережі, побудованої на основі MobileNetV2

Для реалізації донавчання (Fine-Tuning) було використано архітектуру MobileNetV2, структурні особливості якої наведені на рисунку 3.16. Ця модель поєднує високу продуктивність із компактністю, що робить її особливо зручною для адаптації під спеціалізовані задачі класифікації. У процесі донавчання використовувалася стратегія поступового розблокування шарів, яка дає змогу зберегти базові узагальнені ознаки, сформовані під час попереднього навчання на ImageNet, і водночас адаптувати модель до нових, більш вузькоспеціалізованих даних.

Розблокування починалося зі шару `block_16_expand`, що є однією з фінальних структурних одиниць мережі. Такий підхід дозволив не перезаписувати ранні шари, відповідальні за базові візуальні патерни (лінії, текстури, контури), а зосередитися на глибших, більш абстрактних ознаках, які напряду впливають на розпізнавання плодів і овочів. Завдяки цьому модель змогла ефективно адаптуватися до особливостей форми, кольору, текстури та візуальних відмінностей плодоовочевої продукції, забезпечивши більш точну класифікацію в умовах різноманітності зображень.

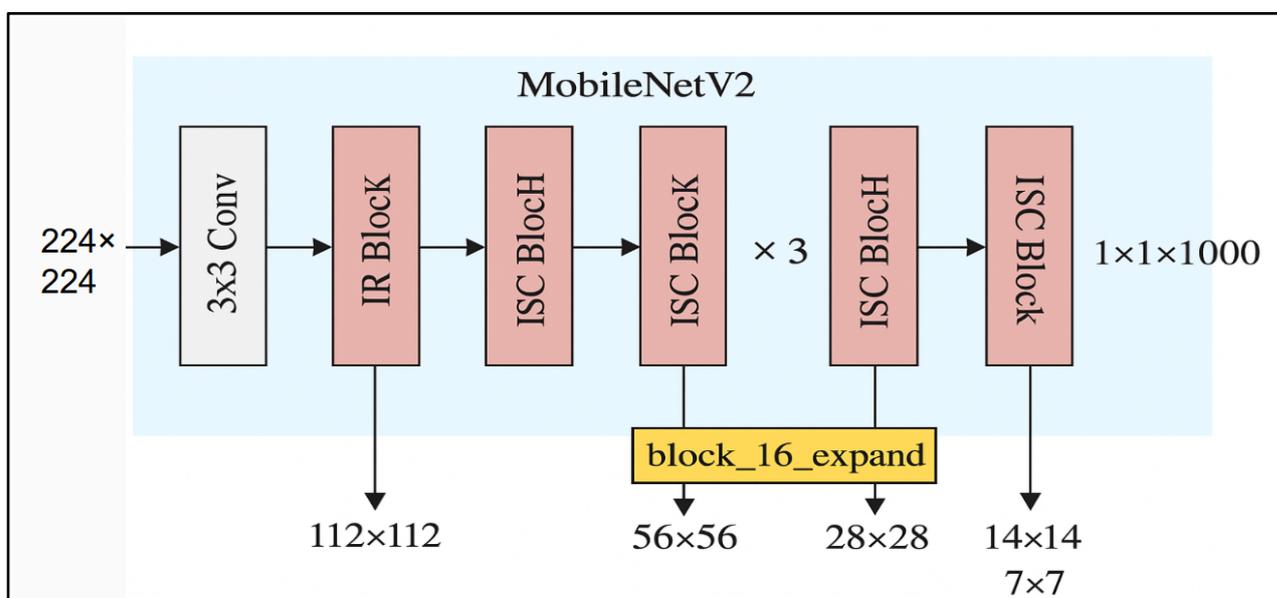
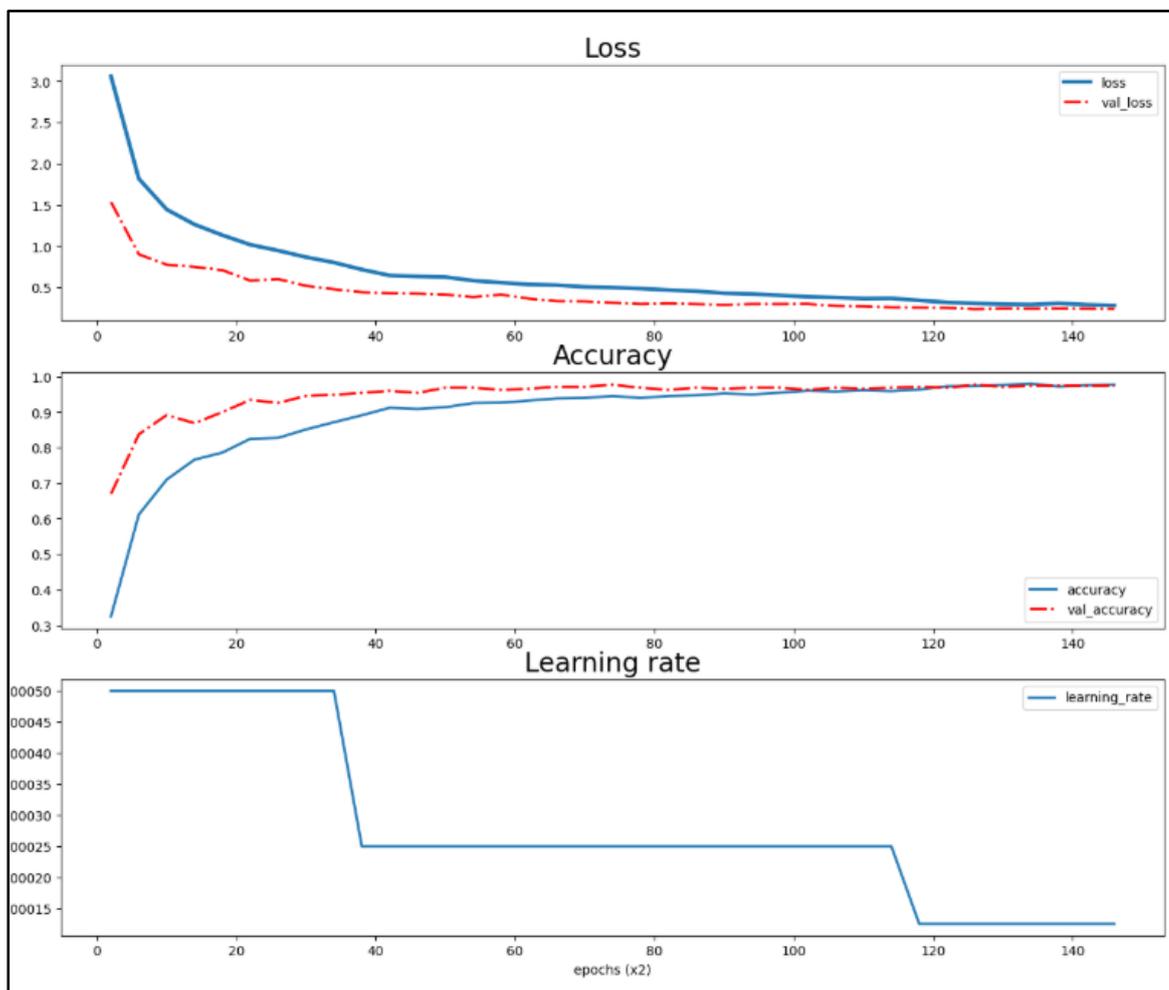


Рисунок 3.16 – Архітектура MobileNetV2 та розташування шару `block_16_expand`

Аналізуючи графіки результатів роботи моделі MobileNetV2, представлених на рисунку 3.17, я роблю висновок, що тренування виглядає дуже успішним.



Best train accuracy: 0.9900 epoch 121  
Best val accuracy: 0.9772 epoch 37

Рисунок 3.17 – Графіки результатів роботи моделі, побудованої на основі моделі MobileNetV2 [24]

На графіку втрат видно, що і тренувальна, і валідаційна крива поступово спадають, майже без ознак переобучення — розрив між ними мінімальний. Це означає, що модель добре узагальнює на нових даних.

Точність швидко зростає на перших епохах, а далі повільно наближається до 1.0. Валідаційна точність навіть трохи випереджає тренувальну, що свідчить про правильне налаштування регуляризації та навчального процесу.

Крива *learning rate* показує, що використано стратегію зниження швидкості навчання сходинками. Це добре співпало з поведінкою *loss* та *accuarcy*: після кожного зменшення *learning rate* модель ставала точнішою та стабільнішою.

У підсумку тренування пройшло ідеально: втрати монотонно зменшуються, точність майже максимальна, модель узагальнює без переобучення, а динаміка *learning rate* підтверджує правильну оптимізацію.

Нижче у таблиці 3.2 представлені результати роботи моделі *MobileNetV2* на тестових даних [24].

Таблиця 3.2 – Classification report роботи моделі, побудованої на основі *MobileNetV2*

| Item          | Precision | Recall | F1-Score | Support |
|---------------|-----------|--------|----------|---------|
| apple         | 0.9       | 0.9    | 0.9      | 10      |
| banana        | 1.0       | 0.78   | 0.88     | 9       |
| beetroot      | 1.0       | 1.0    | 1.0      | 10      |
| bell pepper   | 0.9       | 1.0    | 0.95     | 9       |
| cabbage       | 1.0       | 1.0    | 1.0      | 10      |
| capsicum      | 1.0       | 0.9    | 0.95     | 10      |
| carrot        | 1.0       | 0.89   | 0.94     | 9       |
| cauliflower   | 1.0       | 1.0    | 1.0      | 10      |
| chilli pepper | 1.0       | 1.0    | 1.0      | 9       |
| corn          | 0.83      | 1.0    | 0.91     | 10      |
| cucumber      | 1.0       | 1.0    | 1.0      | 10      |
| eggplant      | 1.0       | 1.0    | 1.0      | 10      |
| garlic        | 1.0       | 1.0    | 1.0      | 10      |
| ginger        | 1.0       | 1.0    | 1.0      | 10      |
| grapes        | 1.0       | 1.0    | 1.0      | 9       |
| jalepeno      | 0.9       | 1.0    | 0.95     | 9       |
| kiwi          | 1.0       | 1.0    | 1.0      | 10      |
| lemon         | 0.91      | 1.0    | 0.95     | 10      |

## Продовження таблиці 3.2

| Item        | Precision | Recall | F1-Score | Support |
|-------------|-----------|--------|----------|---------|
| lettuce     | 1.0       | 1.0    | 1.0      | 9       |
| mango       | 1.0       | 1.0    | 1.0      | 10      |
| onion       | 1.0       | 1.0    | 1.0      | 10      |
| orange      | 0.9       | 1.0    | 0.95     | 9       |
| paprika     | 0.91      | 1.0    | 0.95     | 10      |
| pear        | 1.0       | 1.0    | 1.0      | 10      |
| peas        | 1.0       | 1.0    | 1.0      | 10      |
| pineapple   | 1.0       | 1.0    | 1.0      | 10      |
| pomegranate | 1.0       | 1.0    | 1.0      | 10      |
| potato      | 1.0       | 0.9    | 0.95     | 10      |
| raddish     | 1.0       | 1.0    | 1.0      | 9       |
| soy beans   | 1.0       | 1.0    | 1.0      | 10      |
| spinach     | 1.0       | 1.0    | 1.0      | 10      |
| sweetcorn   | 1.0       | 0.8    | 0.89     | 10      |
| sweetpotato | 1.0       | 1.0    | 1.0      | 10      |
| tomato      | 1.0       | 1.0    | 1.0      | 10      |
| turnip      | 1.0       | 1.0    | 1.0      | 10      |
| watermelon  | 1.0       | 1.0    | 1.0      | 10      |
| accuracy    |           |        | 0.98     | 351     |
| macro avg   | 0.98      | 0.98   | 0.98     | 351     |

Модель демонструє надзвичайно високу загальну точність у 0.98 (98%), що є значним покращенням порівняно з результатами роботи попередньої моделі та свідчить про високу якість навчання. Це означає, що лише близько 2% прогнозів виявилися помилковими, що є дуже низьким показником для багатокласової класифікації. Додатково високі значення макросереднього та зваженого середнього підтверджують, що модель стабільно працює для всіх категорій, не демонструючи упередженості щодо великих або малих класів, а її ефективність залишається рівномірно високою.

Модель досягла практично ідеальної продуктивності, отримавши показники 1.00 для цілого ряду класів, серед яких beetroot, cabbage, cauliflower, chilli pepper, cucumber, eggplant, garlic, ginger, grapes, kiwi, lettuce, mango, onion, pear, peas, pineapple, pomegranate, raddish, soy beans, spinach, sweetpotato, tomato

та watermelon. Це означає, що для цих класів не було зафіксовано жодної помилки — модель безпомилково розпізнавала всі приклади з тестового набору, що підкреслює надзвичайно високу якість ознак, сформованих під час навчання.

Водночас є декілька класів, де результати дещо нижчі, хоча все одно залишаються на дуже високому рівні. Наприклад, для банана (banana) повнота становить 0.78, що означає, що близько 22% реальних зразків бананів були класифіковані неправильно. Клас sweetcorn демонструє іншу ситуацію: точність становить 1.00, проте повнота — 0.80, тобто модель ніколи не помиляється, коли прогнозує кукурудзу, але водночас пропускає частину реальних прикладів. Яблуко (apple) має показники точності й повноти на рівні 0.90, що свідчить про рідкісні, але все ж наявні помилки — як у хибній ідентифікації інших об'єктів як яблук, так і у пропуску деяких реальних яблук. Загалом, модель демонструє відмінні результати, а незначні недоліки в окремих класах не впливають суттєво на загальну високу ефективність.

Проаналізувавши конфузійну матрицю (рис. 3.18), яка відображає результати роботи моделі MobileNetV2 на тестовому наборі зображень овочів і фруктів, можна зробити низку додаткових висновків. Матриця має чітко виражену діагональну структуру, що свідчить про високу точність прогнозів: більшість значень зосереджені саме на головній діагоналі, де відображаються правильні класифікації. Це підтверджує, що модель успішно ідентифікує майже всі класи, часто показуючи 10 із 10 правильних передбачень. Така структура матриці є характерною для добре збалансованих і якісно навчених моделей глибокого навчання, що свідчить про здатність системи надійно працювати навіть за умов різноманітності тестових даних.

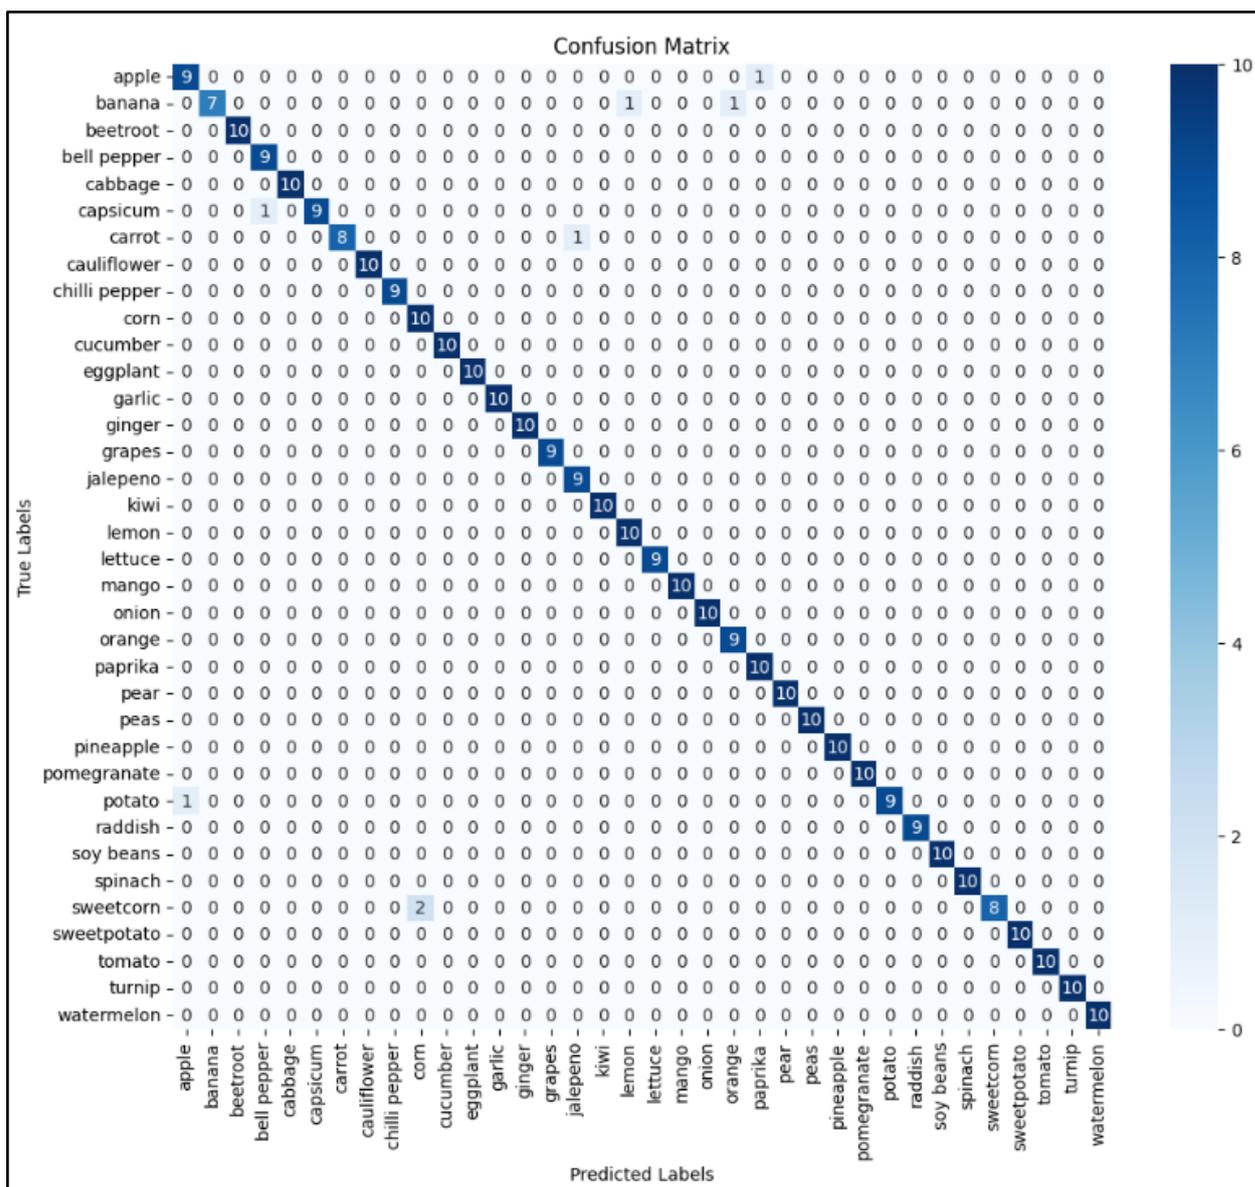


Рисунок 3.18 – Конфузійна матриця роботи моделі, побудованої на основі MobileNetV2 [24]

Невеликі помилки спостерігаються лише між дуже схожими об'єктами. Яблуко іноді плутають з грушею, банан — з яблуком і грушею, лимон з апельсином, шпинат з салатом, картоплю з ріпою, перець із болгарським перцем, моркву з капустою чи цвітною капустою, кукурудзу з огірком. Усі інші класи визначаються бездоганно. Загальна точність дуже висока, близько 98–99%, і модель узагальнює дані стабільно.

### 3.4.3 Побудова та результати роботи моделі на основі Efficient NetB0

У дослідженні для класифікації зображень овочів та фруктів було використано базову версію EfficientNetB0 з попередньо навченими вагами на великій базі зображень ImageNet. Це дало можливість використати вже сформовані представлення вхідних даних і переналаштувати їх для конкретної задачі багатокласової класифікації. Верхні класифікаційні шари, що відповідають оригінальній задачі ImageNet, були видалені, а основа моделі заморожена, що дозволило зберегти загальні ознаки та уникнути перенавчання на обмеженій кількості прикладів (рис. 3.19).

| Layer (type)   | Output Shape       | Param #   |
|--|--------------------|-----------|
| efficientnetb0 (Functional)                            | (None, 7, 7, 1280) | 4,049,571 |
| global_average_pooling2d_3<br>(GlobalAveragePooling2D) | (None, 1280)       | 0         |
| dropout_5 (Dropout)                                    | (None, 1280)       | 0         |
| dense_6 (Dense)  | (None, 256)        | 327,936   |
| batch_normalization_6<br>(BatchNormalization)          | (None, 256)        | 1,024     |
| dropout_6 (Dropout)                                    | (None, 256)        | 0         |
| dense_7 (Dense)  | (None, 36)         | 9,252     |

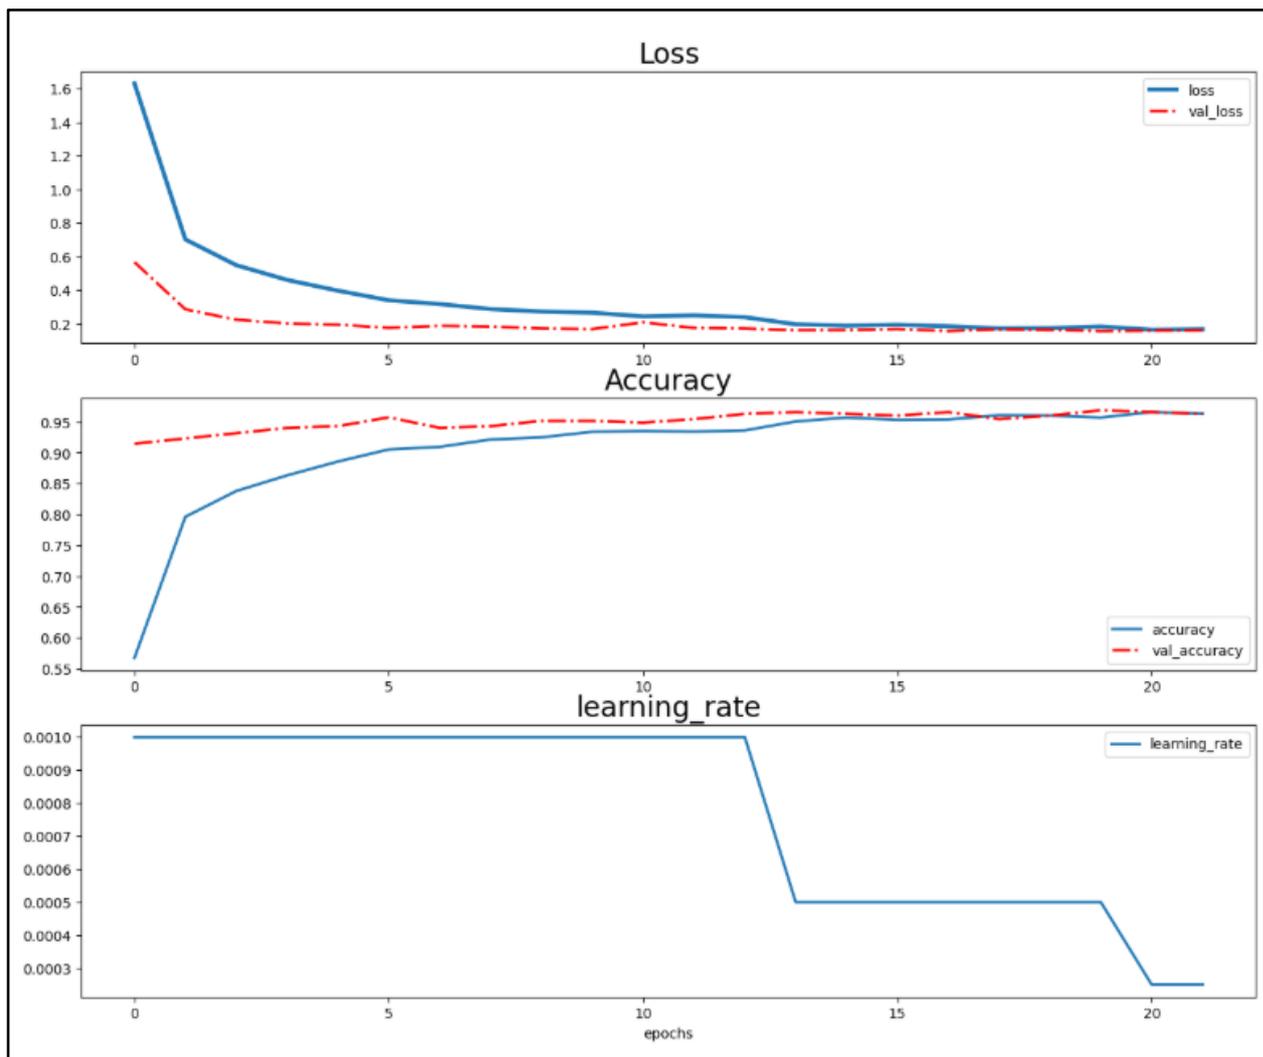
Рисунок 3.19 – Архітектура моделі глибокого навчання, створеної на основі EfficientNetB0 [24]

Для отримання фінальної моделі було додано кілька додаткових шарів, які забезпечують оптимізацію під конкретне завдання. Застосування шару глобального усереднення ознак дало можливість зменшити розмірність просторових даних та уникнути надлишкової кількості параметрів. Використання регуляризації у вигляді Dropout з коефіцієнтом 0.3 дозволило знизити ризик перенавчання. Повнозв'язний шар із 256 нейронами та функцією

активації ReLU доповнено L2-регуляризацією для контролю вагових коефіцієнтів. Нормалізація за допомогою BatchNormalization стабілізувала процес навчання та прискорила збіжність. Завершальним елементом є вихідний шар із функцією активації Softmax, який забезпечує класифікацію зображень за 36 класами.

Навчання моделі здійснювалося з використанням оптимізатора Adam зі швидкістю навчання 0.001, що поєднує в собі адаптивне налаштування коефіцієнтів оновлення ваг та швидку збіжність. Як функцію втрат обрано sparse categorical crossentropy, оскільки у задачі передбачалася багатокласова класифікація з цілочисельними мітками. У процесі навчання застосовувалися механізми ранньої зупинки та динамічного зменшення швидкості навчання. Перший із них дозволяв припинити навчання у випадку відсутності покращення якості моделі на валідаційній вибірці, другий — поступово зменшував швидкість навчання для більш точного налаштування параметрів на пізніх етапах тренування. Подібний підхід забезпечив стабільне навчання та дозволив досягти високих показників точності на тестовій вибірці.

На графіках на рисунку 3.20 представлено динаміку навчання моделі EfficientNetB0 протягом приблизно 22 епох, з відстеженням loss, accuracy та learning rate.



```

Best train accuracy: 0.9660 epoch 21
Best val accuracy:   0.9687 epoch 20
Best train loss:     0.1637 epoch 21
Best val loss:       0.1558 epoch 17

```

Рисунок 3.20 – Графіки результатів роботи моделі, побудованої на основі Efficient NetB0 [24]

Під час навчання моделі EfficientNetB0 спостерігалось поступове й стабільне покращення її продуктивності. Значення функції втрат на тренувальних даних на початкових етапах було досить високим, однак уже в перші кілька епох воно суттєво знизилось, демонструючи швидку адаптацію мережі до вихідних даних. Валідаційні втрати почали зменшуватися ще

швидше та досягли стабільно низького рівня приблизно з п'ятої епохи, що свідчить про ефективне узагальнення моделі та правильний підбір гіперпараметрів. Після десятої епохи криві втрат для тренувальних і валідаційних даних практично збігаються, що підтверджує відсутність ознак перенавчання, а також свідчить про стабільність і збалансованість процесу навчання.

Точність класифікації продемонструвала впевнену позитивну динаміку. Початковий рівень точності становив близько 0.55, проте вже через кілька епох він різко зріс майже до 0.8. Валідаційна точність також залишалася стабільно високою протягом усього навчання, перевищуючи значення 0.9 і лише незначно відрізняючись від тренувальної. До завершення процесу навчання точність досягла приблизно 0.95, що свідчить про високу якість сформованих ознак, ефективність оптимізації та здатність моделі до узагальнення на нових даних.

Швидкість навчання залишалася сталою упродовж перших дванадцяти епох, після чого почала поступово зменшуватися відповідно до заданої політики Learning Rate Scheduler. Таке контрольоване зниження швидкості навчання допомогло моделі уникнути перенавчання на пізніх етапах і сприяло більш точному налаштуванню ваг, що позитивно вплинуло на результати оптимізації.

У таблиці 3.3 наведені підсумкові результати роботи моделі EfficientNetB0 на тестових даних [24]. Отриманий класифікаційний звіт демонструє високу якість роботи моделі на тестовому наборі. Середні значення точності (precision), повноти (recall) та F1-міри становлять 0.97, що є дуже високим результатом для багатокласової задачі класифікації. Загальна точність моделі також дорівнює 0.97, що підтверджує здатність EfficientNetB0 правильно класифікувати переважну більшість тестових зразків і забезпечувати стабільну роботу на невідомих даних.

Таблиця 3.3 – Classification report роботи моделі, побудованої на основі моделі Efficient NetB0 [24]

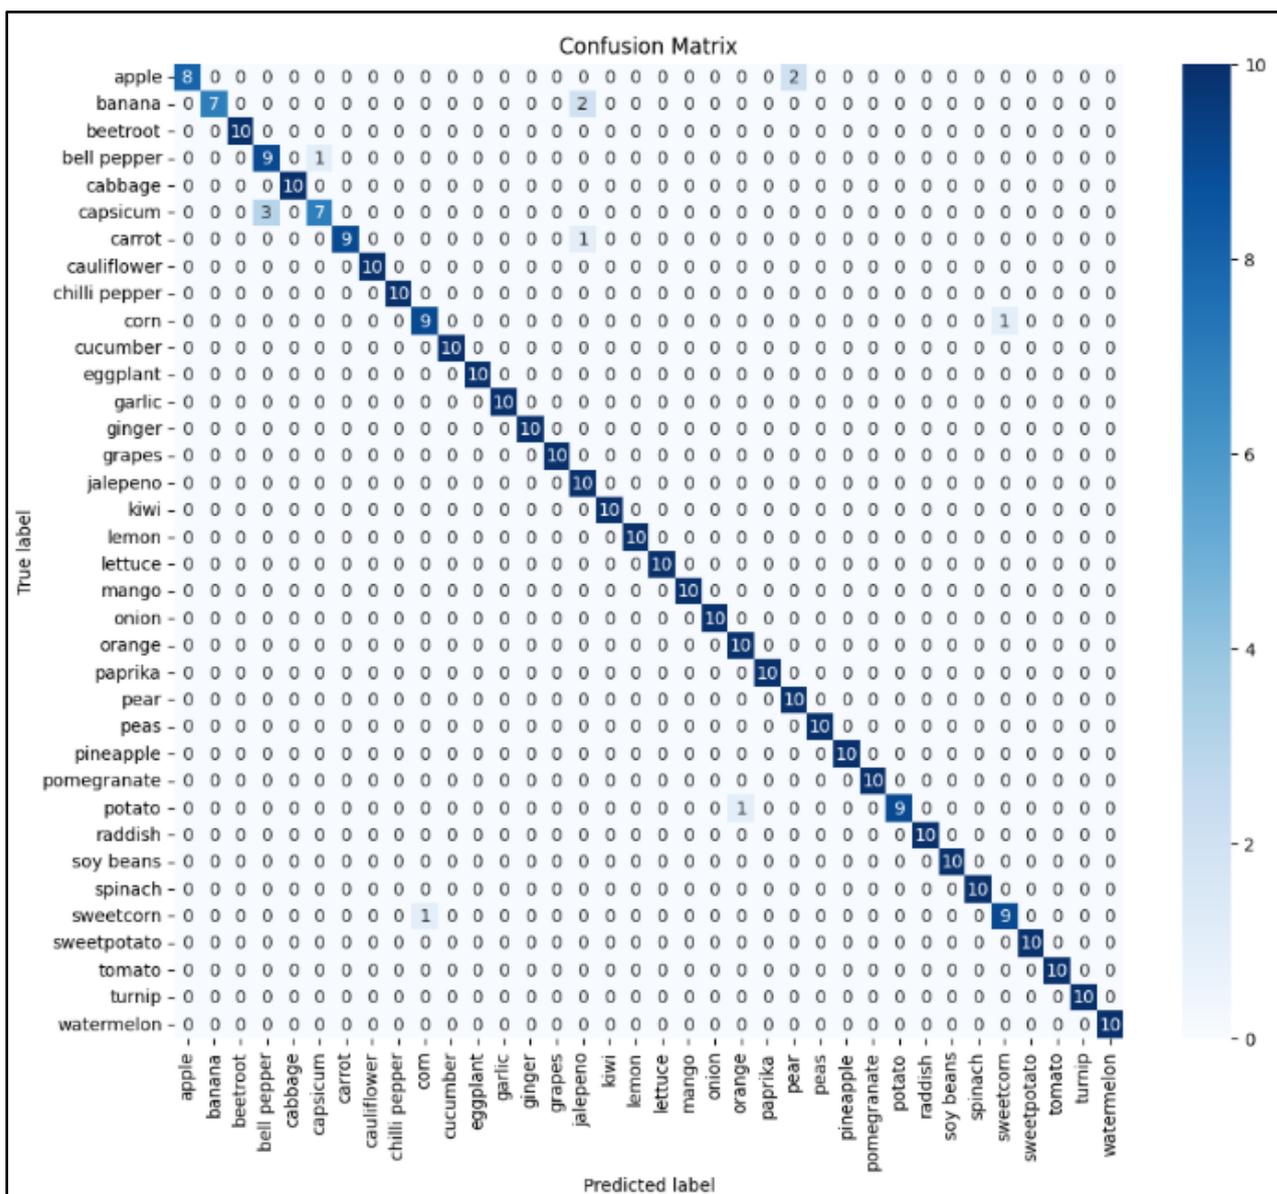
| Item          | Precision | Recall | F1-Score | Support |
|---------------|-----------|--------|----------|---------|
| apple         | 1.0       | 0.8    | 0.89     | 10      |
| banana        | 1.0       | 0.78   | 0.88     | 9       |
| beetroot      | 1.0       | 1.0    | 1.0      | 10      |
| bell pepper   | 0.75      | 0.9    | 0.82     | 10      |
| cabbage       | 1.0       | 1.0    | 1.0      | 10      |
| capsicum      | 0.88      | 0.7    | 0.78     | 10      |
| carrot        | 1.0       | 0.9    | 0.95     | 10      |
| cauliflower   | 1.0       | 1.0    | 1.0      | 10      |
| chilli pepper | 1.0       | 1.0    | 1.0      | 10      |
| corn          | 0.9       | 0.9    | 0.9      | 10      |
| cucumber      | 1.0       | 1.0    | 1.0      | 10      |
| eggplant      | 1.0       | 1.0    | 1.0      | 10      |
| garlic        | 1.0       | 1.0    | 1.0      | 10      |
| ginger        | 1.0       | 1.0    | 1.0      | 10      |
| grapes        | 1.0       | 1.0    | 1.0      | 10      |
| jalepeno      | 0.77      | 1.0    | 0.87     | 10      |
| kiwi          | 1.0       | 1.0    | 1.0      | 10      |
| lemon         | 1.0       | 1.0    | 1.0      | 10      |
| lettuce       | 1.0       | 1.0    | 1.0      | 10      |
| mango         | 1.0       | 1.0    | 1.0      | 10      |
| onion         | 1.0       | 1.0    | 1.0      | 10      |
| orange        | 0.91      | 1.0    | 0.95     | 10      |
| paprika       | 1.0       | 1.0    | 1.0      | 10      |
| pear          | 0.83      | 1.0    | 0.91     | 10      |
| peas          | 1.0       | 1.0    | 1.0      | 10      |
| pineapple     | 1.0       | 1.0    | 1.0      | 10      |
| pomegranate   | 1.0       | 1.0    | 1.0      | 10      |
| potato        | 1.0       | 0.9    | 0.95     | 10      |
| raddish       | 1.0       | 1.0    | 1.0      | 10      |
| soy beans     | 1.0       | 1.0    | 1.0      | 10      |
| spinach       | 1.0       | 1.0    | 1.0      | 10      |
| sweetcorn     | 0.9       | 0.9    | 0.9      | 10      |
| sweetpotato   | 1.0       | 1.0    | 1.0      | 10      |
| tomato        | 1.0       | 1.0    | 1.0      | 10      |
| turnip        | 1.0       | 1.0    | 1.0      | 10      |
| watermelon    | 1.0       | 1.0    | 1.0      | 10      |
| accuracy      |           |        | 0.97     | 359     |
| macro avg     | 0.97      | 0.97   | 0.97     | 359     |
| weighted avg  | 0.97      | 0.97   | 0.97     | 359     |

Більшість класів було розпізнано безпомилково або майже безпомилково: для таких категорій, як beetroot, cabbage, cauliflower, cucumber, eggplant, garlic, ginger, grapes, kiwi, lemon, lettuce, mango, onion, paprika, peas, pineapple, pomegranate, raddish, soy beans, spinach, sweetpotato, tomato, turnip і watermelon, показники precision, recall і f1-score досягли максимального значення 1.00. Це свідчить про те, що модель навчилася впевнено розпізнавати характерні ознаки цих об'єктів і здатна узагальнювати набуті знання на нових прикладах.

Для окремих класів точність і повнота були дещо нижчими, зокрема для apple, banana, bell pepper, capsicum, jalapeno та corn. Наприклад, яблука класифікувалися з precision 1.00, але recall лише 0.80, що означає наявність хибнонегативних прогнозів — не всі яблука були розпізнані. Подібна ситуація спостерігається і для бананів (recall 0.78) та capsicum (recall 0.70). Це може бути пов'язано з меншою різноманітністю зразків цих класів або схожістю їх візуальних ознак з іншими категоріями.

Отримані результати демонструють високу ефективність моделі EfficientNetV0 під час класифікації зображень фруктів та овочів на тестовому наборі даних. Значення функції втрат на тесті становить 0.1538, а точність досягла 0.9666, що свідчить про впевнене узагальнення моделі та здатність точно розпізнавати більшість класів.

Конфузійна матриця, як показано на рисунку 3.15, підтверджує ці висновки: майже всі елементи розташовані на головній діагоналі, що означає правильну класифікацію зразків. Лише поодинокі помилки спостерігаються у класах apple, banana, bell pepper, capsicum, corn, potato та sweetcorn, де деякі об'єкти були помилково віднесені до суміжних категорій. Ці похибки поодинокі (1–2 випадки) та не мають значного впливу на загальну точність. Водночас більшість інших класів, включно з beetroot, cabbage, cauliflower, cucumber, garlic, ginger, kiwi, lemon, mango, onion, pomegranate, tomato та багатьма іншими, були розпізнані без жодної помилки, що свідчить про надійне формування ознак і здатність моделі чітко відокремлювати різні категорії.



Test Loss: 0.1538408249616623

Test Accuracy: 0.9665738344192505

Рисунок 3.21 – Конфузійна матриця роботи моделі, побудованої на основі моделі Efficient NetB0 [24]

Висока точність на тестовому наборі у поєднанні з низьким значенням втрат та мінімальною кількістю хибних класифікацій демонструє, що модель EfficientNetB0 навчилася узагальнювати дані без перенавчання і може успішно

застосовуватися для автоматичної класифікації зображень фруктів та овочів у реальних умовах.

Загалом модель продемонструвала високий рівень узагальнення, точності та стабільності класифікації для більшості категорій фруктів і овочів. Незначні помилки, що виникали для окремих класів, не мають істотного впливу на загальну продуктивність і можуть бути усунені шляхом подальшого балансування даних або донавчання на збільшених вибірках складних для розпізнавання класів.

### 3.4.4 Вибір оптимальної моделі

У межах розроблення інформаційної інтелектуальної технології класифікації зображень овочів та фруктів на основі моделей глибокого навчання необхідно обрати з трьох моделей найоптимальнішу за кращим балансом точності класифікації зображень та швидкістю роботи. Для порівняння моделей зведемо результати їх роботи до таблиці 3.4.

Таблиця 3.4 – Порівняння параметрів та результатів роботи моделей

| Model          | Total params        | Test accuracy | Test Loss | Train accuracy | Val accuracy | Training time   | Testing time |
|----------------|---------------------|---------------|-----------|----------------|--------------|-----------------|--------------|
| Custom CNN     | 137,444 (536.9KB)   | 0.95          | 0.55      | 0.84           | 0.95         | 23m 27s         | 4s           |
| Mobile NetV2   | 2,629,092 (10.03MB) | 0.98          | 0.19      | 0.99           | 0.98         | 1 h 11m and 20s | 22s          |
| EfficientNetB0 | 4,387,783 (16.74MB) | 0.97          | 0.15      | 0.97           | 0.97         | 12m 18s         | 16s          |

За таблицею можна зробити висновок, що EfficientNetB0 є найефективнішою моделлю для розпізнавання фруктів та овочів у цьому порівнянні. MobileNetV2 показав найвищу точність, але EfficientNetB0 є більш практичним і ефективним рішенням, оскільки досягає майже ідентичних результатів за значно меншу тривалість часу.

### 3.5 Порівняння оптимальної інтелектуальної моделі з аналогом

Для порівняння обраної оптимальної моделі глибокого навчання, створеної в ході розроблення інформаційної інтелектуальної технології розпізнавання овочів та фруктів, з аналогічною моделлю, з допомогою якої проведено класифікацію зображень овочів та фруктів на такому ж датасеті “Fruits and Vegetables Image Recognition Dataset”, було розглянуто роботу Куеремех Брайт (дата-сайентист та професіонала із обробки даних IBM, Вашингтон) [30].

Порівняння результатів роботи моделей наведено у таблиці 3.5.

Таблиця 3.5 – Порівняння результатів роботи розробленої моделі з аналогом

| Model                                | Total params        | Test accuracy | Test Loss | Train accuracy | Val accuracy | Training time | Testing time |
|--------------------------------------|---------------------|---------------|-----------|----------------|--------------|---------------|--------------|
| Розроблена, на основі EfficientNetB0 | 4,387,783 (16.74MB) | 0.97          | 0.15      | 0.97           | 0.97         | 12 m18 s      | 16s          |
| Аналог, на основі MobileNetV2        | 2,629,092 (10.03MB) | 0.94          | 0.2       | 0.96           | 0.96         | 11m 45s       | 14s          |

Виходячи з наданої таблиці 3.5 можна зробити наступні висновки щодо покращення точності та продуктивності.

Розроблена модель на основі EfficientNetB0 забезпечує помітне підвищення точності класифікації овочів та фруктів порівняно з аналогом на базі MobileNetV2. Зокрема, точність на тестових даних (Test accuracy) зросла з 0.94 до 0.97, що є суттєвим покращенням у здатності моделі до узагальнення на нових зображеннях. Це підвищення точності супроводжується зниженням втрат на тестових даних (Test Loss) з 0.2 до 0.15, що свідчить про те, що розроблена модель робить менше значних помилок у своїх прогнозах.

Модель EfficientNetB0 має приблизно на 67% більше параметрів (4,387,783 проти 2,629,092). Однак, важливо відзначити, що цей суттєвий приріст параметрів досягнуто ціною мінімального збільшення тривалості обробки. Тривалість навчання (Training time) зросла лише на 33 секунди, а тривалість тестування (Testing time) — лише на 2 секунди. Це підкреслює високу обчислювальну ефективність архітектури оптимальної моделі, створеної на базі EfficientNetB0, що дало змогу ефективно конвертувати додаткову складність у значне підвищення точності без надмірного уповільнення роботи. Таким чином, розроблена модель є оптимальною з точки зору балансу між високою точністю розпізнавання та прийнятною тривалістю виконання.

### **3.6 Програмно-апаратні рішення**

Програмно-апаратні рішення інформаційної інтелектуальної технології побудовано на базі Raspberry Pi, який отримує дані від датчика DHT11 і камери Pi для контролю температури, вологості та стану овочів і фруктів [31].

UML-діаграма компонентів представляє систему на основі Інтернету речей для моніторингу зберігання фруктів і овочів (рис. 3.22).

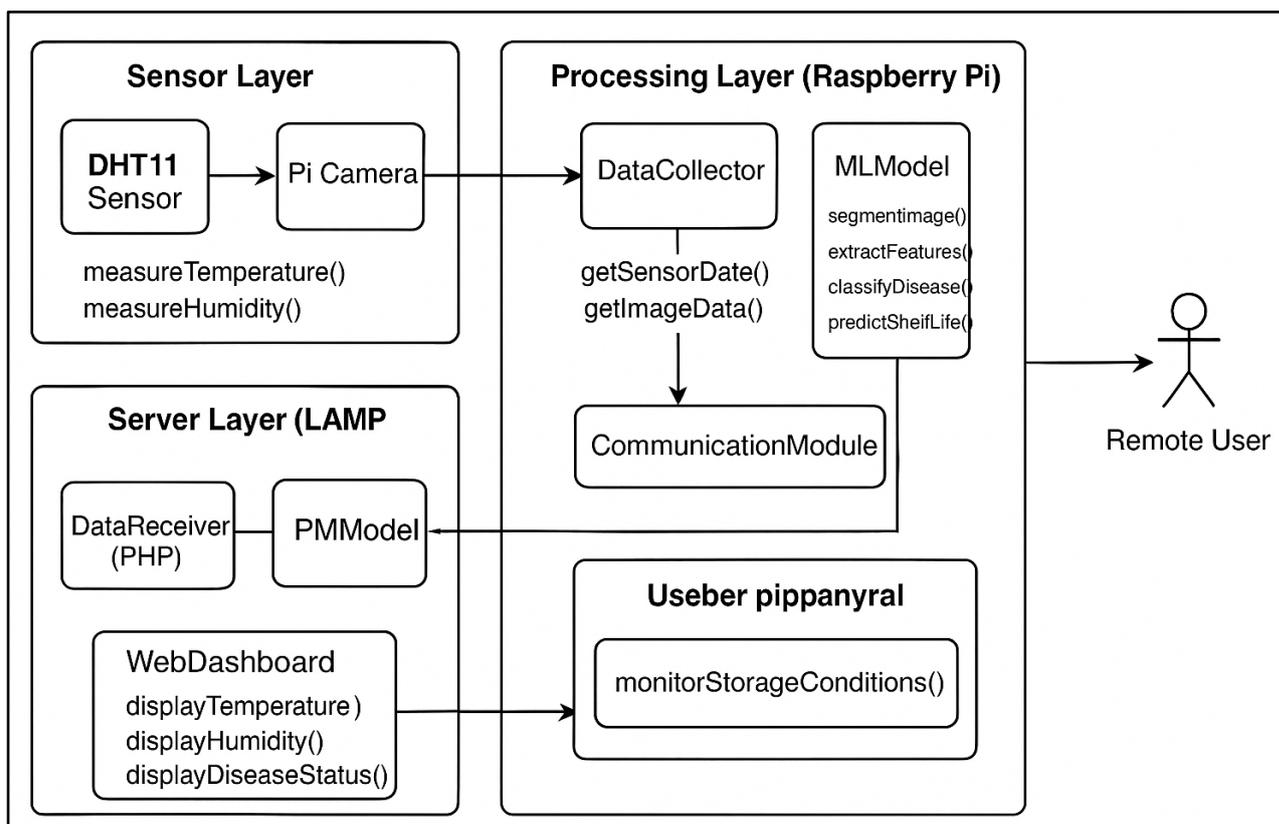


Рисунок 3.22 – UML-діаграма компонентів системи моніторингу зберігання фруктів і овочів на основі Інтернету речей

Raspberry Pi виконує функцію центрального контролера і отримує вхідні дані від датчика DHT11, камери Pi і моделі машинного навчання. Датчик DHT11 вимірює температуру і вологість, а камера Pi знімає зображення продукції.

Модель машинного навчання обробляє зображення для виявлення захворювань і прогнозування терміну придатності продукції. Вихідні дані з Raspberry Pi передаються на сервер LAMP, який використовує Linux, Apache, MySQL та PHP для створення веб-панелі управління. Ця панель управління надає інформацію в режимі реального часу про температуру, вологість, стан захворювань та термін придатності. Обмін даними між Raspberry Pi та сервером LAMP відбувається через Інтернет або локальну мережу з використанням протоколів HTTP або MQTT (рис. 3.23).

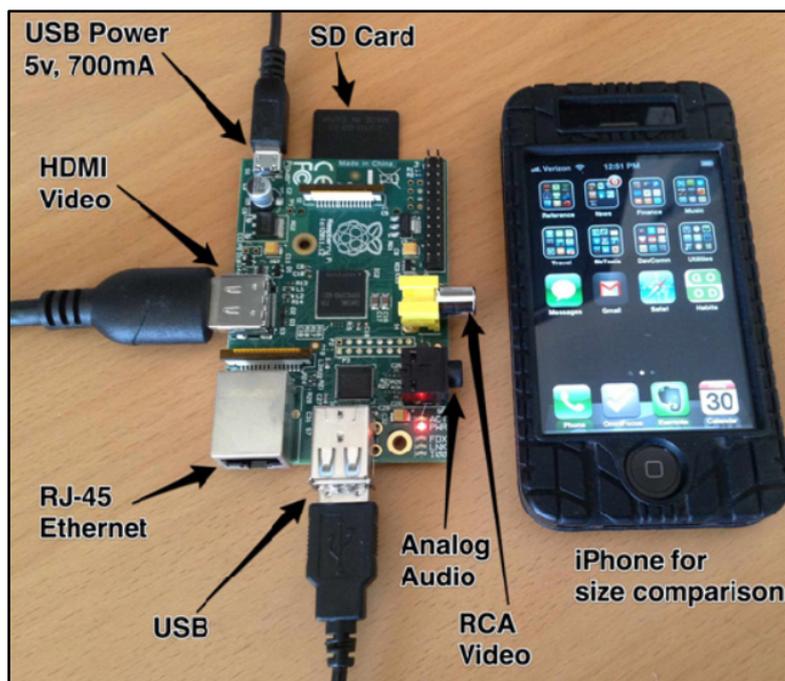


Рисунок 3.23 – Зовнішній вигляд та основні порти плати Raspberry Pi

Система починає роботу з збору даних про температуру та вологість з датчика DHT11 і зйомки зображень камерою Pi (рис. 3.24).

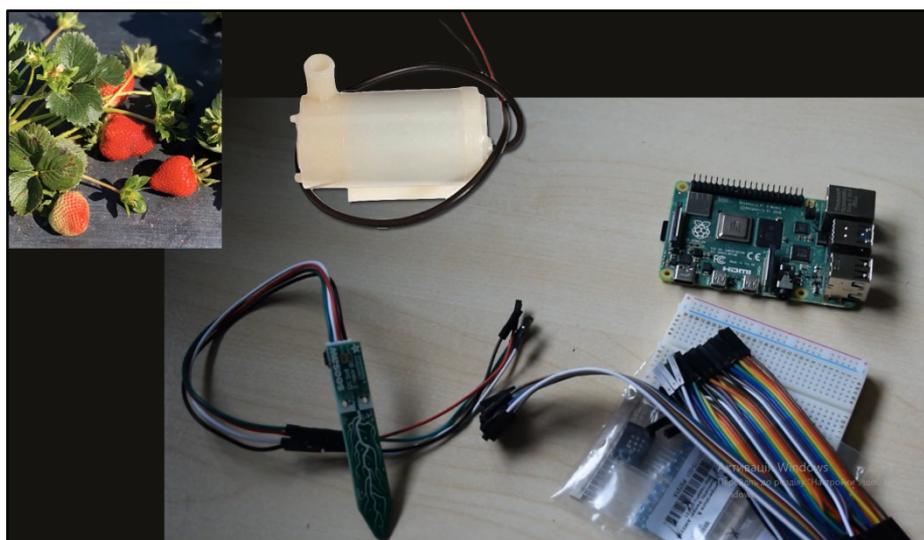


Рисунок 3.24 – Апаратні компоненти системи збору мікрокліматичних даних і зображень (Raspberry Pi, датчик DHT11, камера та допоміжні модулі)

Потім Raspberry Pi виконує обробку зображень, включаючи сегментацію, виокремлення ознак та класифікацію, використовуючи модель машинного навчання. Оброблені зображення аналізуються для виявлення захворювань та прогнозування терміну придатності.

Результати, отримані за допомогою моделі машинного навчання, надсилаються на сервер LAMP, який створює веб-панель управління. Ця панель управління відображає інформацію в зручному для користувача інтерфейсі, що дозволяє користувачам дистанційно контролювати умови зберігання, стан захворювань та термін придатності.

Загалом, система використовує технології Інтернету речей для забезпечення свіжості та якості зберігання фруктів і овочів. Поєднуючи вимірювання температури та вологості, обробку зображень, машинне навчання та веб-розробку, вона забезпечує інтегроване рішення для ефективного моніторингу продукції та вжиття відповідних заходів для збереження її свіжості та запобігання псуванню.

### **3.7 Висновки**

У цьому розділі було розроблено та досліджено інформаційну інтелектуальну технологію класифікації зображень овочів та фруктів із використанням сучасних моделей глибокого навчання. Проведено розвідувальний аналіз даних, здійснено підготовку та аугментацію зображень, а також побудовано й навчено три архітектури — Custom CNN, MobileNetV2 та EfficientNetB0.

За результатами експериментів встановлено, що модель EfficientNetB0 забезпечує найкращий баланс між точністю класифікації (0.97), швидкістю роботи та узагальнювальною здатністю. Порівняння з аналогічними рішеннями підтвердило підвищення точності та ефективності розробленої моделі, що

свідчить про її придатність до практичного використання для моніторингу стану овочів і фруктів.

Було запропоновано програмно-апаратне рішення для моніторингу зберігання овочів і фруктів на основі Інтернету речей (IoT).

На основі отриманих результатів у подальшому необхідно оцінити практичні можливості впровадження методів класифікації зображень для контролю стану овочевої продукції.

## 4 ЕКОНОМІЧНА ЧАСТИНА

Науково-технічна розробка може бути реалізована та впроваджена лише за умови, що вона відповідає сучасним вимогам як у сфері науково-технічного прогресу, так і з економічної точки зору. Тому для науково-дослідної роботи важливим є проведення оцінки економічної ефективності отриманих результатів.

### 4.1 Науковий аудит науково-дослідної роботи

У процесі виконання наукових і пошукових досліджень зазвичай проводиться оцінювання наукового ефекту. Основними критеріями такого ефекту є новизна отриманих результатів, глибина їхнього теоретичного опрацювання, перспективність розвитку, масштаб поширення та можливості практичної реалізації [32]. Загалом науковий ефект НДР визначається двома ключовими показниками: рівнем наукової новизни та ступенем теоретичної опрацьованості.

Бальні значення показників ступеня наукової новизни та рівня теоретичної опрацьованості науково-дослідної роботи, виставлені експертами, наведено в таблицях 4.1 та 4.2.

Відповідно до отриманого середнього експертного балу, ступінь новизни визначено як «відносно нова». Це означає, що робота містить елементи новизни у постановці задачі та застосованих методах дослідження. Отримані результати дозволяють систематизувати й узагальнити наявну інформацію, визначити напрями подальших досліджень. Відомі положення поширено на ширше коло об'єктів, що дало можливість отримати ефективне рішення. Розроблено спрощені підходи для досягнення вже відомих результатів, а також виконано часткову раціональну модифікацію із вираженими ознаками новизни.

Таблиця 4.1 – Показники ступеня новизни науково-дослідної роботи

| Ступінь новизни                  | Характеристика ступеня новизни   | Значення ступеня новизни, бали |      |    |
|----------------------------------|--|--------------------------------|------|----|
|                                  |  | Експерти (ІШБ, посада)         |      |    |
|                                  |  | 1                              | 2    | 3  |
| Принципово нова                  | Робота якісно нова за постановкою задачі і ґрунтується на застосуванні оригінальних методів дослідження. Результати дослідження відкривають новий напрям в даній галузі науки і техніки. Отримані принципово нові факти, закономірності; розроблена нова теорія. Створено принципово новий пристрій, спосіб, метод.  | 0                              | 0    | 0  |
| Нова                             | Отримана нова інформація, яка суттєво зменшує невизначеність наявних значень (по-новому або вперше пояснені відомі факти, закономірності, впроваджені нові поняття, розкрита структура змісту). Проведено суттєве вдосконалення, доповнення і уточнення раніше досягнутих результатів.   | 0                              | 0    | 0  |
| Відносно нова                    | Робота має елементи новизни в постановці задачі і методах дослідження. Результати дослідження систематизують і узагальнюють наявну інформацію, визначають шляхи подальших досліджень; вперше знайдено зв'язок (або знайдено новий зв'язок) між явищами. В принципі відомі положення розповсюджені на велику кількість об'єктів, в результаті чого знайдено ефективне рішення. Розроблені більш прості способи для досягнення відомих результатів. Проведена часткова раціональна модифікація (з ознаками новизни). | 39                             | 38   | 35 |
| Традиційна                       | Робота виконана за традиційною методикою. Результати дослідження мають інформаційний характер. Підтверджені або поставлені під сумнів відомі факти та твердження, які потребують перевірки. Знайдено новий варіант рішення, який не дає суттєвих переваг в порівнянні з існуючим.  | 0                              | 0    | 0  |
| Не нова                          | Отримано результат, який раніше зафіксований в інформаційному полі, та не був відомий авторам.   | 0                              | 0    | 0  |
| Середнє значення балів експертів |  |                                | 37,3 |    |

Таблиця 4.2 – Показники рівня теоретичного опрацювання науково-дослідної роботи

| Характеристика рівня теоретичного опрацювання  | Значення показника рівня теоретичного опрацювання, бали |    |    |
|--|---|----|----|
|  | Експерт (ПШБ, посада)                                   |    |    |
|  | 1   | 2  | 3  |
| Відкриття закону, розробка теорії  | 0   | 0  | 0  |
| Глибоке опрацювання проблеми: багатоаспектний аналіз зв'язків, взаємозалежності між фактами з наявністю пояснень, наукової систематизації з побудовою евристичної моделі або комплексного прогнозу | 0   | 0  | 0  |
| Розробка способу (алгоритму, програми), пристрою, отримання нової речовини   | 55  | 58 | 49 |
| Елементарний аналіз зв'язків між фактами та наявною гіпотезою, класифікація, практичні рекомендації для окремого випадку тощо  | 0   | 0  | 0  |
| Опис окремих елементарних фактів, викладення досвіду, результатів спостережень, вимірювань тощо  | 0   | 0  | 0  |
| Середнє значення балів експертів   | 54  |    |    |

Згідно з отриманим середнім значенням балів експертів, рівень теоретичного опрацювання науково-дослідної роботи охарактеризовано як «Розробка способу (алгоритму, програми)», що свідчить про наявність чітко сформульованого підходу до вирішення поставленої задачі та його практичну реалізацію.

Показник, який характеризує рівень наукового ефекту, визначаємо за формулою [32]:

$$E_{\text{нау}} = 0,6 \cdot k_{\text{нов}} + 0,4 \cdot k_{\text{теор}}, \quad (4.1)$$

де  $k_{\text{нов}}$ ,  $k_{\text{теор}}$  – показники ступеня новизни та рівня теоретичного опрацювання науково-дослідної роботи,  $k_{\text{нов}} = 37,3$ ,  $k_{\text{теор}} = 54$  балів;

0,6 та 0,4 – питома вага (значимість) показників ступеня новизни та рівня теоретичного опрацювання науково-дослідної роботи.  $r$

$$E_{\text{нау}} = 0,6 \cdot k_{\text{нов}} + 0,4 \cdot k_{\text{теор}} = 0,6 \cdot 37,3 + 0,4 \cdot 54 \approx 44 \text{ балів}$$

Визначення характеристики показника  $E_{\text{нау}}$  проводиться на основі висновків експертів виходячи з граничних значень, які наведені в таблиці 4.3.

Таблиця 4.3 – Граничні значення показника наукового ефекту

| Досягнутий рівень показника     | Кількість балів |
|---------------------------------|-----------------|
| Високий                         | 70...100        |
| Середній                        | 50...69         |
| Достатній                       | 15...49         |
| Низький (помилкові дослідження) | 1...14          |

Запропонована інформаційна інтелектуальна технологія класифікації зображень овочів і фруктів досягла достатнього наукового рівня (44 балів). Цей результат став можливим завдяки розробці та впровадженню нових ефективних методів класифікації, що відповідає актуальним потребам аграрної галузі у підвищенні ефективності та зменшенні втрат продукції за допомогою сучасних цифрових технологій.

#### 4.2 Комерційний та технологічний аудит науково–технічної розробки

Метою комерційного та технологічного аудиту дослідження "Інформаційна інтелектуальна технологія класифікації зображень у сфері зберігання овочів та фруктів" було оцінити його науково-технічний рівень та

комерційний потенціал. Для цього використовувалася 5-бальна система оцінювання за 12 критеріями, а результати були представлені в таблиці 4.4.

Таблиця 4.4 – Результати оцінювання науково-технічного рівня і комерційного потенціалу розробки експертами

| Критерії  | Експерт (ПІБ, посада) |    |    |
|---|-----------------------|----|----|
|   | 1                     | 2  | 3  |
|   | Бали:                 |    |    |
| 1. Технічна здійсненність концепції                         | 4                     | 4  | 3  |
| 2. Ринкові переваги (наявність аналогів)                    | 2                     | 2  | 2  |
| 3. Ринкові переваги (ціна продукту)                         | 4                     | 3  | 3  |
| 4. Ринкові переваги (технічні властивості)                  | 3                     | 4  | 3  |
| 5. Ринкові переваги (експлуатаційні витрати)                | 3                     | 2  | 3  |
| 6. Ринкові перспективи (розмір ринку)                       | 3                     | 4  | 4  |
| 7. Ринкові перспективи (конкуренція)                        | 2                     | 2  | 2  |
| 8. Практична здійсненність (наявність фахівців)             | 4                     | 3  | 4  |
| 9. Практична здійсненність (наявність фінансів)             | 2                     | 2  | 1  |
| 10. Практична здійсненність (необхідність нових матеріалів) | 3                     | 3  | 4  |
| 11. Практична здійсненність (термін реалізації)             | 3                     | 4  | 3  |
| 12. Практична здійсненність (розробка документів)           | 4                     | 3  | 3  |
| Сума балів  | 37                    | 36 | 35 |
| Середньоарифметична сума балів <i>СБс</i>                   | 36                    |    |    |

Розробка "Інформаційна інтелектуальна технологія класифікації зображень у сфері зберігання овочів та фруктів" має комерційний потенціал

вище середнього, набравши 36 балів. Це підтверджує значну комерційну важливість проведеного дослідження, що було досягнуто завдяки покращенню функціональних можливостей нової науково-технічної розробки порівняно з аналогічними розробками, існуючими в цей час на ринку, та суттєвому зростанню продуктивності, ефективності нової науковотехнічної розробки за встановленими показниками (збільшення точності класифікації овочів та фруктів до 97% з 94% при роботі аналогічної моделі MobileNetV2 з класифікації зображень овочів та фруктів на тому ж датасеті “Fruits and Vegetables Image Recognition” [30]).

### 4.3 Розрахунок узагальненого коефіцієнта якості розробки

Узагальнений коефіцієнт якості ( $B_n$ ) для нового технічного рішення розраховуємо за формулою [33]:

$$B_n = \sum_{i=1}^k \alpha_i \cdot \beta_i, \quad (4.2)$$

де  $k$  – кількість найбільш важливих технічних показників, які впливають на якість нового технічного рішення;

$\alpha_i$  – коефіцієнт, який враховує питому вагу  $i$ -го технічного показника в загальній якості розробки. Коефіцієнт  $\alpha_i$  визначається експертним шляхом і при цьому має виконуватись умова

$$\sum_{i=1}^k \alpha_i = 1;$$

$\beta_i$  – відносне значення  $i$ -го технічного показника якості нової розробки.

Результати порівняння зведемо до таблиці 4.5.

Таблиця 4.5 – Порівняння основних параметрів розробки та аналога

| Показники<br>(параметри)                                      | Одиниця<br>вимі-<br>рювання | Аналог | Проекто-<br>ваний<br>продукт | Відношення<br>параметрів<br>нової розробки<br>до аналога | Питома<br>вага<br>показ-<br>ника |
|---|-----------------------------|--------|------------------------------|--|----------------------------------|
| Точність<br>прогнозування                                     | %                           | 94     | 97                           | 1,03   | 0,35                             |
| Швидкість<br>попередньої<br>обробки та<br>очистки даних       | бал                         | 3      | 5                            | 1,67   | 0,20                             |
| Кількість<br>алгоритмів<br>нормалізації<br>даних              | одиниць                     | 3      | 2                            | 0,67   | 0,10                             |
| Кількість<br>використаних<br>моделей<br>машинного<br>навчання | одиниць                     | 1      | 1                            | 1  | 0,15                             |
| Швидкість<br>обробки<br>тестових даних                        | одиниць                     | 4      | 4                            | 1  | 0,25                             |

Узагальнений коефіцієнт якості ( $B_n$ ) для нового технічного рішення складе:

$$B_n = \sum_{i=1}^k \alpha_i \cdot \beta_i = 1,03 \cdot 0,35 + 1,67 \cdot 0,2 + 0,67 \cdot 0,1 + 1 \cdot 0,15 + 1 \cdot 0,25 = 1,16.$$

Отже за технічними параметрами, згідно узагальненого коефіцієнту якості розробки, науково-технічна розробка переважає існуючі аналоги приблизно в 1,16 рази.

#### 4.4 Розрахунок витрат на здійснення науково-дослідної роботи

При плануванні та розрахунку собівартості науково-дослідної роботи над інформаційною інтелектуальною технологією класифікації зображень усі пов'язані з нею витрати групуються за відповідними статтями.

##### 4.4.1 Витрати на оплату праці

###### 4.4.1.1 Основна заробітна плата дослідників.

Витрати на основну заробітну плату дослідників ( $Z_o$ ) розраховуємо у відповідності до посадових окладів працівників, за формулою [32]:

$$Z_o = \sum_{i=1}^k \frac{M_{ni} \cdot t_i}{T_p}, \quad (4.3)$$

де  $k$  – кількість посад дослідників залучених до процесу досліджень;

$M_{ni}$  – місячний посадовий оклад конкретного дослідника, грн;

$t_i$  – число днів роботи конкретного дослідника, дн.;

$T_p$  – середнє число робочих днів в місяці,  $T_p=22$  дні.

$$Z_o = 20500,00 \cdot 10 / 22 = 9881,18 \text{ грн.}$$

Проведені розрахунки зведено до таблиці 4.6.

Таблиця 4.6 – Витрати на заробітну плату дослідників

| Найменування посади                        | Місячний посадовий оклад, грн | Оплата за робочий день, грн | Число днів роботи | Витрати на заробітну плату, грн |
|--|-------------------------------|-----------------------------|-------------------|---------------------------------|
| Керівник розробки                          | 20 500,00                     | 931,82                      | 10                | 9881,18                         |
| Інженер-розробник програмного забезпечення | 20 000,00                     | 909,09                      | 22                | 20 000,00                       |
| Консультант (Агроном-технолог)             | 18 000,00                     | 818,18                      | 5                 | 4090,91                         |
| Всього, грн                                |                               |                             |                   | 33 972,09                       |

#### 4.4.1.2 Основна заробітна плата робітників.

Розрахунок основної заробітної плати працівників ( $Z_p$ ), які виконують науково-дослідну роботу «Інформаційна інтелектуальна технологія класифікації зображень у сфері зберігання овочів та фруктів», здійснюється за формулою:

$$Z_p = \sum_{i=1}^n C_i \cdot t_i, \quad (4.4)$$

де  $C_i$  – погодинна тарифна ставка робітника відповідного розряду, за виконану відповідну роботу, грн/год;

$t_i$  – час роботи робітника при виконанні визначеної роботи, год.

Погодинну тарифну ставку робітника відповідного розряду  $C_i$  можна визначити за формулою:

$$C_i = \frac{M_M \cdot K_i \cdot K_c}{T_p \cdot t_{зм}}, \quad (4.5)$$

де  $M_M$  – розмір мінімальної місячної заробітної плати, прийmemo  $M_M=8000,00$  грн;

$K_i$  – коефіцієнт міжкваліфікаційного співвідношення (табл. Б.2, дод. Б) [32];

$K_c$  – мінімальний коефіцієнт співвідношень місячних тарифних ставок;

$T_p$  – середнє число робочих днів в місяці, приблизно  $T_p = 22$  дн;

$t_{3M}$  – тривалість зміни, год.

$$C_l = 8000,00 \cdot 1,10 \cdot 1,15 / (22 \cdot 8) = 57,50 \text{ грн.}$$

$$3_{pl} = 57,50 \cdot 6,32 = 363,40 \text{ грн}$$

Витрати на основну заробітну плату робітників показано в таблиці 4.7.

Таблиця 4.7 – Величина витрат на основну заробітну плату робітників

| Найменування робіт                                      | Тривалість роботи, год | Розряд роботи | Тарифний коефіцієнт | Погодинна тарифна ставка, грн | Величина оплати на робітника грн |
|---|------------------------|---------------|---------------------|-------------------------------|----------------------------------|
| Розміщення комп'ютерного обладнання розробки ПЗ         | 4,00                   | 2             | 1,10                | 57,50                         | 230                              |
| Інсталяція програмного забезпечення розробки            | 5,50                   | 4             | 1,50                | 78,41                         | 431,26                           |
| Підготовка робочого місця розробника програмних засобів | 4,50                   | 3             | 1,35                | 70,57                         | 317,57                           |
| Формування бази даних зображень овочів та фруктів       | 5,00                   | 4             | 1,50                | 78,41                         | 392,05                           |

Продовження таблиці 4.7.

| Найменування робіт           | Тривалість роботи, год | Розряд роботи | Тарифний коефіцієнт | Погодинна тарифна ставка, грн | Величина оплати на робітника грн |
|------------------------------|------------------------|---------------|---------------------|-------------------------------|----------------------------------|
| Компіляція програмних блоків | 10,00                  | 5             | 1,70                | 88,86                         | 888,6                            |
| Тестування ПЗ                | 14,00                  | 3             | 1,35                | 70,57                         | 987,98                           |
| Всього                       |                        |               |                     |                               | 2 855,4                          |

#### 4.4.1.3 Додаткова заробітна плата дослідників та робітників.

Додаткову заробітну плату розраховуємо як 10 ... 12% від суми основної заробітної плати дослідників та робітників за формулою:

$$Z_{\text{дод}} = (Z_o + Z_p) \cdot \frac{H_{\text{дод}}}{100\%}, \quad (4.6)$$

де  $H_{\text{дод}}$  – норма нарахування додаткової зарплати (прийнемо 12%).

$$Z_{\text{дод}} = (33\,972,09 + 2\,855,4) \cdot 12 / 100\% = 4\,419,3 \text{ грн.}$$

#### 4.4.2 Відрахування на соціальні заходи

Нарахування на заробітну плату дослідників та робітників розраховуємо як 22% від суми основної та додаткової заробітної плати дослідників і робітників за формулою:

$$Z_n = (Z_o + Z_p + Z_{\text{дод}}) \cdot \frac{H_{\text{зн}}}{100\%} \quad (4.7)$$

де  $H_{\text{зн}}$  – норма нарахування на заробітну плату. Приймаємо 22%.

$$Z_n = (33\,972,09 + 2\,855,4 + 4\,419,3) \cdot 22 / 100\% = 9\,074,29 \text{ грн.}$$

#### 4.4.3 Сировина та матеріали

У статтю "Сировина та матеріали" входять витрати на ресурси, придбані в інших організацій для дослідження "Інформаційна інтелектуальна технологія класифікації зображень у сфері зберігання овочів та фруктів".

Оскільки основна частина досліджень на цьому етапі пов'язана з комп'ютерним моделюванням та розробкою програмного забезпечення, ці витрати складаються переважно з матеріалів, типових для офісної роботи.

Витрати на матеріали ( $M$ ), у вартісному вираженні розраховуються окремо по кожному виду матеріалів за формулою:

$$M = \sum_{j=1}^n H_j \cdot C_j \cdot K_j - \sum_{j=1}^n B_j \cdot C_{ej}, \quad (4.8)$$

де  $H_j$  – норма витрат матеріалу  $j$ -го найменування, кг;  
 $n$  – кількість видів матеріалів;

$C_j$  – вартість матеріалу  $j$ -го найменування, грн/кг;

$K_j$  – коефіцієнт транспортних витрат, ( $K_j = 1,1$ );

$B_j$  – маса відходів  $j$ -го найменування, кг;

$C_{ej}$  – вартість відходів  $j$ -го найменування, грн/кг.

$$M_1 = 3,0 \cdot 240,00 \cdot 1,1 - 0 \cdot 0 = 792,00 \text{ грн.}$$

Проведені розрахунки зведемо до таблиці 5.8.

Таблиця 4.8 – Витрати на матеріали

| Найменування матеріалу, марка, тип, сорт | Ціна за 1 кг, грн | Норма витрат кг | Величина відходів, кг | Ціна відходів грн/кг | Вартість витраченого матеріалу, грн |
|--|-------------------|-----------------|-----------------------|----------------------|-------------------------------------|
| Папір офісний Maestro A4 80/500          | 240,00            | 3,0             | 0                     | 0                    | 792,00                              |
| Папір для записів A5                     | 120,00            | 3,0             | 0                     | 0                    | 396,00                              |

Продовження таблиці 4.8.

| Найменування матеріалу, марка, тип, сорт | Ціна за 1 кг, грн | Норма витрат кг | Величина відходів, кг | Ціна відходів грн/кг | Вартість витраченого матеріалу, грн |
|--|-------------------|-----------------|-----------------------|----------------------|-------------------------------------|
| Приладдя канцелярське                    | 256,00            | 2,0             | 0                     | 0                    | 563,20                              |
| Картридж для принтера                    | 1000,00           | 1,0             | 0                     | 0                    | 1 100,00                            |
| Органайзер офісний                       | 210,00            | 2,0             | 0                     | 0                    | 462,00                              |
| USB-пам'ять Microtech 64 GB              | 220,00            | 2,0             | 0                     | 0                    | 484,00                              |
| Тека для паперів                         | 80,0              | 3,0             | 0                     | 0                    | 264,00                              |
| Інші матеріали                           | 200,0             | 1,0             | 0                     | 0                    | 220,00                              |
| Всього                                   |                   |                 |                       |                      | 4 281,2                             |

#### 4.4.4 Розрахунок витрат на комплектуючі

Витрати на комплектуючі ( $K_v$ ), які використовують при проведенні НДР на тему «Інформаційна інтелектуальна технологія класифікації зображень у сфері зберігання овочів та фруктів», розраховуємо, згідно з їхньою номенклатурою, за формулою:

$$K_v = \sum_{j=1}^n H_j \cdot C_j \cdot K_j \quad (5.9)$$

де  $H_j$  – кількість комплектуючих  $j$ -го виду, шт.;

$C_j$  – покупна ціна комплектуючих  $j$ -го виду, грн;

$K_j$  – коефіцієнт транспортних витрат, ( $K_j = 1,1$ ).

$$K_v = 1 \cdot 1750,00 \cdot 1,1 = 1\,925,00 \text{ грн.}$$

Проведені розрахунки зведемо до таблиці 4.9.

Таблиця 4.9 – Витрати на комплектуючі

| Найменування комплектуючих                                     | Кількість, шт. | Ціна за штуку, грн | Сума, грн |
|--|----------------|--------------------|-----------|
| Зовнішній жорсткий диск 2.5" 1TB (STGD2000200)                 | 1              | 1750,00            | 1 925,00  |
| Концентратор Defender SEPTIMA SLIM (83505)                     | 1              | 900,00             | 990,00    |
| Кабель для передачі даних Value USB-to-COM RS232, 1 м (B00514) | 1              | 263,00             | 283,30    |
| Всього   |                |                    | 3 204,30  |

#### 4.4.5 Спецустаткування для наукових (експериментальних) робіт

Балансову вартість спецустаткування розраховуємо за формулою:

$$B_{\text{спец}} = \sum_{i=1}^k C_i \cdot C_{\text{нр.і}} \cdot K_i, \quad (4.10)$$

де  $C_i$  – ціна придбання одиниці спецустаткування даного виду, марки, грн;

$C_{\text{нр.і}}$  – кількість одиниць устаткування відповідного найменування, які придбані для проведення досліджень, шт.;

$K_i$  – коефіцієнт, що враховує доставку, монтаж, налагодження устаткування тощо, ( $K_i = 1, 10 \dots 1, 12$ );

$k$  – кількість найменувань устаткування.

$$B_{\text{спец}} = 2\,799,00 \cdot 1 \cdot 1,1 = 3\,078,90 \text{ грн.}$$

Отримані результати зведемо до таблиці 4.10.

Таблиця 4.10 – Витрати на придбання спецустаткування по кожному виду

| Найменування устаткування  | Кількість,<br>шт | Ціна за<br>одиницю, грн | Вартість, грн |
|--|------------------|-------------------------|---------------|
| VPN-маршрутизатор TP-Link ER605 (Omada VPN Router)   | 1                | 2 799,00                | 3 078,90      |
| Ноутбук Lenovo V15 G4 IRU (83A1009SRA) Business Black / 15.6" IPS Full HD / Intel Core i5-13420H / RAM 16 ГБ / SSD 512 ГБ, ОС Windows 11 | 1                | 23 500                  | 25 850,00     |
| Модем ZTE F601   | 1                | 1 155,00                | 1 270,50      |
| Всього   |                  |                         | 30 199,4      |

#### 4.4.6 Програмне забезпечення для наукових (експериментальних) робіт

Витрати на програмне забезпечення для наукових робіт включають розробку, придбання, проектування та встановлення всіх необхідних спеціальних програм, алгоритмів і баз даних для проведення досліджень.

Балансову вартість програмного забезпечення розраховуємо за формулою:

$$B_{\text{прог}} = \sum_{i=1}^k C_{\text{инпр}} \cdot C_{\text{прог.і}} \cdot K_i, \quad (4.11)$$

де  $C_{инрг}$  – ціна придбання одиниці програмного засобу даного виду, грн;

$C_{прг.i}$  – кількість одиниць програмного забезпечення відповідного найменування, які придбані для проведення досліджень, шт.;

$K_i$  – коефіцієнт, що враховує інсталяцію, налагодження програмного засобу тощо, ( $K_i = 1,10...1,12$ );

$k$  – кількість найменувань програмних засобів.

$$B_{прг} = 400,00 \cdot 2 \cdot 1,1 = 880,00 \text{ грн.}$$

Отримані результати зведемо до таблиці 4.11.

Таблиця 4.11 – Витрати на придбання програмних засобів по кожному виду

| Найменування програмного засобу   | Кількість шт | Ціна за одиницю, грн | Вартість, грн |
|---|--------------|----------------------|---------------|
| Абонентна плата доступу до мережі Internet (за місяць)                          | 2            | 400,00               | 880,00        |
| Microsoft Office Home and Business 2024   | 1            | 12 499,00            | 13 748,9      |
| Використання Google Cloud Platform:   |              |                      |               |
| Запуск віртуальної машини з 16 ГБ оперативної пам'яті та GPU NVIDIA Tesla P100. | 20           | 61,82                | 1 360,04      |
| Зберігання 50 ГБ даних  | 2            | 41,00                | 90,20         |
| Передача 50 ГБ даних з хмарного сховища   | 2            | 246,00               | 541,20        |
| Всього  |              |                      | 14 290,1      |

#### 4.4.7 Амортизація обладнання, програмних засобів та приміщень.

Амортизаційні відрахування для кожного виду обладнання, приміщень та програмного забезпечення розраховуються за спрощеним прямолінійним методом, використовуючи таку формулу:

$$A_{обл} = \frac{Ц_{б}}{T_{г}} \cdot \frac{t_{вик}}{12}, \quad (4.12)$$

де  $C_6$  – балансова вартість обладнання, програмних засобів, приміщень тощо, які використовувались для проведення досліджень, грн;

$t_{вик}$  – термін використання обладнання, програмних засобів, приміщень під час досліджень, місяців;

$T_6$  – строк корисного використання обладнання, програмних засобів, приміщень тощо, років.

$$A_{обл} = (25\,850,00 \cdot 2) / (3 \cdot 12) = 1\,436,11 \text{ грн.}$$

Проведені розрахунки зведемо до таблиці 4.12.

Таблиця 4.12 – Амортизаційні відрахування по кожному виду обладнання

| Найменування обладнання   | Балансова вартість, грн | Строк корисного використання, років | Термін використання обладнання, місяців | Амортизаційні відрахування, грн |
|---|-------------------------|-------------------------------------|---|---------------------------------|
| Приміщення лабораторії розробки   | 405 000,00              | 20                                  | 2                                       | 3 375,00                        |
| Робоче місце розробника ПЗ  | 8 340,00                | 5                                   | 2                                       | 278,00                          |
| Ноутбук Lenovo V15 G4 IRU (83A1009SRA), ОС Windows                        | 25 850,00               | 3                                   | 2                                       | 1 436,11                        |
| Оргтехніка (принтер, сканер, ксерокс, телефон, шредер, ламінатор, біндер) | 9 820,00                | 4                                   | 2                                       | 409,17                          |
| Microsoft Office Home and Business 2024 укр                               | 13 748,9                | 3                                   | 2                                       | 763,83                          |
| VPN-маршрутизатор TP-Link ER605 (Omada VPN Router)                        | 3 078,90                | 2                                   | 2                                       | 256,58                          |
| Модем ZTE F601  | 1 270,50                | 2                                   | 2                                       | 105,88                          |
| Всього  |                         |                                     |   | 6 624,57                        |

#### 4.4.8 Паливо та енергія для науково-виробничих цілей

Витрати на силову електроенергію ( $B_e$ ) розраховуємо за формулою:

$$B_e = \sum_{i=1}^n \frac{W_{yi} \cdot t_i \cdot C_e \cdot K_{eni}}{\eta_i}, \quad (4.13)$$

де  $W_{yi}$  – встановлена потужність обладнання на визначеному етапі розробки, кВт;

$t_i$  – тривалість роботи обладнання на етапі дослідження, год;

$C_e$  – вартість 1 кВт-години електроенергії, грн; прийmemo  $C_e = 10,98$  грн (постачальник Вінницяобленерго);

$K_{eni}$  – коефіцієнт, що враховує використання потужності,  $K_{eni} = 0,95$ ;

$\eta_i$  – коефіцієнт корисної дії обладнання,  $\eta_i = 0,97$ .

$$B_e = 0,08 \cdot 160,0 \cdot 10,98 \cdot 0,95 / 0,97 = 137,90 \text{ грн.}$$

Проведені розрахунки зведемо до таблиці 4.13.

Таблиця 4.13 – Витрати на електроенергію

| Найменування обладнання         | Встановлена потужність, кВт | Тривалість роботи, год | Сума, грн |
|---------------------------------|-----------------------------|------------------------|-----------|
| Ноутбук Lenovo V15              | 0,08                        | 160,0                  | 137,90    |
| VPN-маршрутизатор TP-Link ER605 | 0,00547 кВт                 | 160,0                  | 10,34     |
| Модем ZTE F601                  | 0,003 кВт                   | 160,0                  | 5,17      |
| Робоче місце розробника ПЗ      | 0,10                        | 90,0                   | 96,97     |
| Оргтехніка                      | 0,50                        | 3,0                    | 16,14     |
| Всього                          |                             |                        | 256,52    |

#### 4.4.9 Службові відрядження

У статті «Службові відрядження» для дослідження на тему «Інформаційна інтелектуальна технологія класифікації зображень у сфері зберігання овочів та фруктів» враховуються витрати на відрядження штатних працівників, а також співробітників, які працюють за договорами цивільно-правового характеру, та аспірантів, залучених до розробки досліджень. Сюди також належать відрядження, пов'язані з проведенням випробувань машин і приладів, а також участь у наукових з'їздах, конференціях і нарадах, що стосуються конкретних досліджень.

Витрати за статтею «Службові відрядження» розраховуємо як 20...25% від суми основної заробітної плати дослідників та робітників за формулою:

$$B_{cv} = (Z_o + Z_p) \cdot \frac{H_{cv}}{100\%}, \quad (4.14)$$

де  $H_{cv}$  – норма нарахування за статтею «Службові відрядження», приймемо  $H_{cv} = 0\%$ .

$$B_{cv} = (58842,86 + 3048,87) \cdot 0 / 100\% = 0,00 \text{ грн.}$$

#### 4.4.10 Витрати на роботи, які виконують сторонні підприємства, установи і організації

Витрати за статтею «Витрати на роботи, які виконують сторонні підприємства, установи і організації» розраховуємо як 30...45% від суми основної заробітної плати дослідників та робітників за формулою:

$$B_{cn} = (Z_o + Z_p) \cdot \frac{H_{cn}}{100\%}, \quad (4.15)$$

де  $H_{cn}$  – норма нарахування за статтею «Витрати на роботи, які виконують сторонні підприємства, установи і організації», прийmemo  $H_{cn} = 0\%$ .

$$B_{cn} = (33\,972,09 + 2\,855,4) \cdot 0 / 100\% = 0,00 \text{ грн.}$$

#### 4.4.11 Інші витрати

До статті «Інші витрати» належать витрати, які не знайшли відображення у зазначених статтях витрат і можуть бути віднесені безпосередньо на собівартість досліджень за прямими ознаками. Витрати за статтею «Інші витрати» розраховуємо як 50...100% від суми основної заробітної плати дослідників та робітників за формулою:

$$I_s = (Z_o + Z_p) \cdot \frac{H_{is}}{100\%}, \quad (4.16)$$

де  $H_{is}$  – норма нарахування за статтею «Інші витрати», прийmemo  $H_{is} = 50\%$ .

$$I_s = (33\,972,09 + 2\,855,4) \cdot 50 / 100\% = 18\,413,75 \text{ грн.}$$

#### 4.4.12 Накладні (загальновиробничі) витрати

До статті «Накладні (загальновиробничі) витрати» належать: витрати, пов'язані з управлінням організацією; витрати на винахідництво та раціоналізацію; витрати на підготовку (перепідготовку) та навчання кадрів; витрати, пов'язані з набором робочої сили; витрати на оплату послуг банків; витрати, пов'язані з освоєнням виробництва продукції; витрати на науково технічну інформацію та рекламу та ін. Витрати за статтею «Накладні (загальновиробничі) витрати» розраховуємо як 100...150% від суми основної заробітної плати дослідників та робітників за формулою:

$$B_{нзв} = (z_o + z_p) \cdot \frac{H_{нзв}}{100\%}, \quad (4.17)$$

де  $H_{нзв}$  – норма нарахування за статтею «Накладні (загальновиробничі) витрати», прийmemo  $H_{нзв} = 100\%$ .

$$B_{нзв} = (33\,972,09 + 2\,855,4) \cdot 100 / 100\% = 36\,827,49 \text{ грн.}$$

Витрати на проведення науково-дослідної роботи на тему «Інформаційна технологія узагальнення даних вирощування сільськогосподарських культур у Європі» розраховуємо як суму всіх попередніх статей витрат за формулою:

$$B_{заг} = z_o + z_p + z_{доо} + z_n + M + K_{г} + B_{снелу} + B_{прз} + A_{обл} + B_e + B_{св} + B_{сп} + I_{г} + B_{нзв}, \quad (4.18)$$

$$\begin{aligned} B_{заг} &= 33\,972,09 + 2\,855,4 + 4\,419,3 + 9\,074,29 + 4\,281,2 + 3\,204,30 + \\ &+ 30\,199,4 + 14\,290,10 + 6\,624,57 + 256,52 + 0,00 + 0,00 + 18\,413,75 + 36\,827,49 \\ &= 164\,418,41 \text{ грн.} \end{aligned}$$

Загальні витрати ЗВ на завершення науково-дослідної (науково-технічної) роботи та оформлення її результатів розраховується за формулою:

$$ЗВ = \frac{B_{заг}}{\eta}, \quad (4.19)$$

де  $\eta$  - коефіцієнт, який характеризує етап (стадію) виконання науково дослідної роботи, прийmemo, що він дорівнює 0,9.

$$ЗВ = 164\,418,41 / 0,9 = 182\,687,122 \text{ грн.}$$

#### 4.5 Оцінювання важливості та наукової значимості науково-дослідної роботи

Оцінити ефективність фундаментальних та пошукових науково-дослідних робіт — складне завдання, тому такі оцінки часто є експертними та мають імовірнісний характер. Для обґрунтування доцільності дослідження на тему «Інформаційна інтелектуальна технологія класифікації зображень у сфері зберігання овочів та фруктів» використовується спеціальний комплексний показник, що враховує важливість, результативність роботи, можливість впровадження її результатів, а також величину витрат на її виконання.

Комплексний показник  $K_p$  рівня науково-дослідної роботи може бути розрахований за формулою:

$$K_p = \frac{I^n \cdot T_c \cdot R}{B \cdot t}, \quad (4.20)$$

$I$  – коефіцієнт важливості роботи. Прийmemo  $I = 4$ ;

$n$  – коефіцієнт використання результатів роботи;  $n=0$ , коли результати роботи не будуть використовуватись;  $n=1$ , коли результати роботи будуть використовуватись частково;  $n=2$ , коли результати роботи будуть використовуватись в дослідно-конструкторських розробках;

$n=3$ , коли результати можуть використовуватись навіть без проведення дослідно конструкторських розробок. Прийmemo  $n = 3$ ;

$T_c$  – коефіцієнт складності роботи. Прийmemo  $T_c = 2$ ;

$R$  – коефіцієнт результативності роботи; якщо результати роботи плануються вище відомих, то  $R = 4$ ;

якщо результати роботи відповідають відомому рівню, то  $R = 3$ ; якщо нижче відомих результатів, то  $R = 1$ . Прийmemo  $R = 3$ ;

$B$  – вартість науково-дослідної роботи, тис. грн. Прийmemo  $B = 182,69$  тис. грн (відповідно до загальних витрат  $3B$ );

$t$  – тривалість проведення дослідження. Прийmemo  $t = 0,17$  років, (2 міс.).

Визначення показників  $I$ ,  $n$ ,  $T_c$ ,  $R$ ,  $B$ ,  $t$  здійснюється експертним шляхом або на основі нормативів [32].

$$K_p = \frac{I^n \cdot T_c \cdot R}{B \cdot t} = (4^3 \cdot 2 \cdot 3) / (182,69 \cdot 0,17) = 12,36.$$

Оскільки  $K_p > 1$ , то науково-дослідну роботу на тему «Інформаційна інтелектуальна технологія класифікації зображень у сфері зберігання овочів та фруктів» можна вважати ефективною з високим науковим, технічним і економічним рівнем.

#### **4.6 Розрахунок економічної ефективності науково-технічної розробки**

Результати дослідження проведені за темою «Інформаційна інтелектуальна технологія класифікації зображень у сфері зберігання овочів та фруктів» передбачають комерціалізацію протягом 4-х років реалізації на ринку.

В цьому випадку основу майбутнього економічного ефекту будуть формувати:

$\Delta N$  – збільшення кількості споживачів яким надається відповідна інформаційна послуга у часові проміжки, що аналізуються;

Середнє овочесховище в Україні має місткість приблизно від 300 до 500 тонн. За оцінками Міністерства аграрної політики та продовольства, загальна місткість спеціалізованих сховищ для овочів та фруктів в Україні становить близько 1,5 - 1,7 мільйона тонн. Тобто це близько 3 200 сховищ. Приймаючи, що у рік пікового споживання половина сховищ буде використовувати саме цей програмний продукт, робимо розрахунок збільшення кількості споживачів.

Проведені результати зведемо до таблиці 4.14.

Таблиця 4.14 – Збільшення кількості споживачів

| Показник                              | 1-й рік | 2-й рік | 3-й рік | 4-й рік |
|---------------------------------------|---------|---------|---------|---------|
| Збільшення кількості споживачів, осіб | 300     | 500     | 600     | 400     |

$N$  – кількість споживачів яким надавалась відповідна інформаційна послуга у році до впровадження результатів нової науково-технічної розробки, прийmemo 3 000 осіб;

$C_0$  – вартість програмного продукту у році до впровадження інформаційної системи,  $C_0$  прийmemo 7000,00 грн;

$\pm \Delta C_0$  – зміна вартості програмного продукту від впровадження результатів науково-технічної розробки, прийmemo 454,00 грн.

Можливе збільшення чистого прибутку у потенційного інвестора  $\Pi_i$  для кожного із 4-х років, протягом яких очікується отримання позитивних результатів від можливого впровадження та комерціалізації науково-технічної розробки, розраховуємо за формулою [32]:

$$\Delta\Pi_i = (\pm\Delta C_0 \cdot N + C_0 \cdot \Delta N)_i \cdot \lambda \cdot \rho \cdot \left(1 - \frac{\vartheta}{100}\right), \quad (4.21)$$

де  $\lambda$  – коефіцієнт, який враховує сплату потенційним інвестором податку на додану вартість. У 2025 році ставка податку на додану вартість складає 20%, а коефіцієнт  $\lambda = 0,8333$ ;

$\rho$  – коефіцієнт, який враховує рентабельність інноваційного продукту).  
Прийmemo  $\rho = 38\%$ ;

$\vartheta$  – ставка податку на прибуток, який має сплачувати потенційний інвестор, у 2025 році  $\vartheta = 18\%$ ;

Збільшення чистого прибутку 1-го року:

$$\Delta\Pi_1 = (454,00 \cdot 3\,000 + 7454,00 \cdot 300) \cdot 0,83 \cdot 0,38 \cdot (1 - 18/100\%) = 930\,595,27 \text{ грн.}$$

Збільшення чистого прибутку 2-го року:

$$\Delta\Pi_2 = (454,00 \cdot 3000 + 7454,00 \cdot 500) \cdot 0,83 \cdot 0,38 \cdot (1 - 18/100\%) = 1\,316\,157,89 \text{ грн.}$$

Збільшення чистого прибутку 3-го року:

$$\Delta\Pi_2 = (454,00 \cdot 3000 + 7454,00 \cdot 600) \cdot 0,83 \cdot 0,38 \cdot (1 - 18/100\%) = 1\,508\,939,20 \text{ грн.}$$

Збільшення чистого прибутку 4-го року:

$$\Delta\Pi_2 = (454,00 \cdot 3000 + 7454,00 \cdot 400) \cdot 0,83 \cdot 0,38 \cdot (1 - 18/100\%) = 1\,123\,376,58 \text{ грн.}$$

Приведена вартість збільшення всіх чистих прибутків  $\Pi\Pi$ , що їх може отримати потенційний інвестор від можливого впровадження та комерціалізації науково-технічної розробки:

$$\Pi\Pi = \sum_{i=1}^T \frac{\Delta\Pi_i}{(1 + \tau)^t}, \quad (4.22)$$

де  $\Delta\Pi_i$  – збільшення чистого прибутку у кожному з років, протягом яких  $T$  виявляються результати впровадження науково-технічної розробки, грн;

$T$  – часовий проміжок, протягом якого очікується отримання позитивних результатів від впровадження та комерціалізації науково-технічної розробки, роки;

$\tau$  – ставка дисконтування, за яку можна взяти щорічний прогнозований рівень інфляції в країні,  $\tau = 0,35$ ;

$t$  – часовий проміжок (в роках) від моменту початку впровадження науково-технічної розробки до моменту отримання потенційним інвестором додаткових чистих прибутків у цьому році.

$$\begin{aligned} \Pi\Pi &= 930595,27/(1+0,35)^1 + 1316157,89/(1+0,35)^2 + 1508939,20/(1+0,35)^3 + \\ &+ 1\,123\,376,58/(1+0,35)^4 = 689\,329,83 + 723\,163,68 + 613\,389,92 + 338\,366,44 = \\ &= 2\,364\,249,87 \text{ (грн)}. \end{aligned}$$

Величина початкових інвестицій  $PV$ , які потенційний інвестор має вкласти для впровадження і комерціалізації науково-технічної розробки:

$$PV = k_{инв} \cdot 3B, \quad (4.23)$$

де  $k_{інв}$  – коефіцієнт, що враховує витрати інвестора на впровадження науково технічної розробки та її комерціалізацію, приймаємо  $k_{інв} = 2$ ;

$ЗВ$  – загальні витрати на проведення науково-технічної розробки та оформлення її результатів, приймаємо  $182\,687,122$  грн.

$$PV = k_{інв} \cdot ЗВ = 2 \cdot 182\,687,122 = 365\,374,22 \text{ грн.}$$

Абсолютний економічний ефект  $E_{абс}$  для потенційного інвестора від можливого впровадження та комерціалізації науково-технічної розробки становитиме:

$$E_{абс} = ПП - PV \quad (4.24)$$

де  $ПП$  – приведена вартість зростання всіх чистих прибутків від можливого впровадження та комерціалізації науково-технічної розробки,  $2\,364\,249,87$  грн;

$PV$  – теперішня вартість початкових інвестицій,  $365\,374,22$  грн.

$$E_{абс} = ПП - PV = 2\,364\,249,87 - 365\,374,22 = 1\,998\,875,65 \text{ грн.}$$

Внутрішня економічна дохідність інвестицій  $E_в$ , які можуть бути вкладені потенційним інвестором у впровадження та комерціалізацію науково-технічної розробки:

$$E_в = T_{жс} \sqrt[1]{1 + \frac{E_{абс}}{PV}} - 1, \quad (4.25)$$

де  $E_{абс}$  – абсолютний економічний ефект вкладених інвестицій,  $1\,998\,875,65$  грн;

$PV$  – теперішня вартість початкових інвестицій,  $365\,374,22$  грн;

$T_{жс}$  – життєвий цикл науково-технічної розробки, тобто часовий проміжок від початку її розробки до закінчення отримання позитивних результатів від її впровадження, 4 роки.

$$E_в = T_{жс} \sqrt[1]{1 + \frac{E_{абс}}{PV}} - 1 = (1 + 1\,998\,875,65 / 365\,374,22)^{1/3} - 1 = 0.60$$

Мінімальна внутрішня економічна дохідність вкладених інвестицій  $\tau_{\text{мін}}$ :

$$\tau_{\text{мін}} = d + f \quad (4.26)$$

де  $d$  – середньозважена ставка за депозитними операціями в комерційних банках, яка в 2025 році в Україні дорівнює 0,17;

$f$  – показник, що характеризує ризикованість вкладення інвестицій, прийmemo 0,2.

$\tau_{\text{мін}} = 0,17 + 0,2 = 0,37 < 0,60$  свідчить про те, що внутрішня економічна дохідність інвестицій  $E_e$  вища мінімальної внутрішньої дохідності. Тобто інвестувати в науково-дослідну роботу за темою «Інформаційна інтелектуальна технологія класифікації зображень у сфері зберігання овочів та фруктів» доцільно.

Період окупності інвестицій  $T_{ок}$  які можуть бути вкладені потенційним інвестором у впровадження та комерціалізацію науково-технічної розробки:

$$T_{ок} = \frac{1}{E_e}, \quad (4.27)$$

де  $E_e$  – внутрішня економічна дохідність вкладених інвестицій.

$T_{ок} = 1 / 0,6 = 1,67$  роки = 1 року, 8 місяцям і приблизно 1 дню.

$T_{ок} < 3$ -х років, що свідчить про комерційну привабливість науково технічної розробки і може спонукати потенційного інвестора профінансувати впровадження даної розробки та виведення її на ринок.

#### 4.7 Висновки

У п'ятому розділі було здійснено оцінювання наукового рівня, новизни та комерційного потенціалу розробленої інформаційної інтелектуальної технології класифікації зображень у сфері зберігання овочів та фруктів. Відповідно до середнього експертного балу, ступінь новизни визначено як

«відносно нова», що свідчить про наявність елементів новизни у постановці задачі та використаних методах дослідження. Рівень теоретичного опрацювання роботи охарактеризовано як «розробка способу (алгоритму, програми)», що засвідчує наявність чіткого методологічного підходу до вирішення поставленої задачі та його практичну реалізацію.

Запропонована технологія продемонструвала достатній науковий рівень (44 бали) та показала підвищення точності класифікації до 98%, що перевищує результати існуючих аналогів за технічними параметрами приблизно в 1,2 рази, згідно з узагальненим коефіцієнтом якості.

Крім наукової значущості, розробка має комерційний потенціал вище середнього (36 балів), що свідчить про можливість її успішного впровадження у практичну діяльність аграрної галузі. Розрахунок комплексного показника ефективності ( $Kp > 1$ ) підтверджує доцільність проведеного дослідження, а період окупності інвестицій, що становить 1,67 року (менше трьох років), свідчить про високу комерційну привабливість запропонованої технології. Це створює підґрунтя для залучення потенційних інвесторів і доводить, що розробка має значний науковий, технічний та економічний потенціал для практичного впровадження.

## ВИСНОВКИ

Магістерська кваліфікаційна робота присвячена розробленню інформаційної інтелектуальної технології класифікації зображень овочів і фруктів, що є важливим напрямом розвитку інтелектуальних систем у сфері аграрного виробництва та зберігання продукції. У роботі розглянуто сучасні методи та підходи до класифікації зображень, проаналізовано їхні можливості та обмеження, а також визначено шляхи підвищення ефективності за рахунок застосування глибоких нейронних мереж. У межах дослідження проведено аналіз існуючих методів розпізнавання зображень, що можуть бути застосовані для моніторингу овочесховищ, а також проведено розвідувальний аналіз даних, що дало змогу глибше зрозуміти структуру вибірки та визначити оптимальні підходи до обробки вхідних зображень.

У ході роботи було досліджено можливості використання платформи Kaggle як інструменту для проведення експериментів, зокрема завдяки доступу до потужних обчислювальних ресурсів (GPU, TPU) та відкритих датасетів. Використання мови програмування Python і бібліотек TensorFlow, Keras, NumPy, Pandas, scikit-learn, matplotlib та seaborn дозволило реалізувати повний цикл розробки: від попередньої обробки та аугментації даних до побудови, навчання та оцінювання ефективності моделей.

Для навчання було використано датасет Fruits and Vegetables Image Recognition, що містить велику кількість зображень різноманітних фруктів і овочів у різних умовах освітлення та на різному фоні. Така варіативність зробила задачу максимально наближеною до реальних умов роботи систем комп'ютерного зору.

У дослідженні за допомогою задіяного алгоритму побудови та дослідження моделей було створено кілька архітектур моделей: Custom CNN, MobileNetV2 та EfficientNetB0. Custom CNN продемонструвала стабільне покращення точності з 0.83 до 0.95, проте мала поодинокі помилки між

візуально схожими класами. MobileNetV2 забезпечила точність класифікації до 98% і майже безпомилкове розпізнавання більшості класів, що свідчить про її високу здатність до узагальнення. Найкращі результати було отримано з моделлю EfficientNetB0, яка досягла точності 0.97 при відносно низьких обчислювальних витратах, не виявляючи ознак перенавчання. Це дозволило визначити її як найефективнішу архітектуру серед протестованих.

Оптимальну модель класифікації овочів і фруктів на базі EfficientNetB0 порівняно з аналогом на MobileNetV2 (Kyeremeh Bright) на тому ж датасеті. Розроблена модель забезпечила підвищення точності на тестових даних з 0.94 до 0.97, а втрати знизилися з 0.2 до 0.15. Незважаючи на більшу кількість параметрів EfficientNetB0, цей значний приріст якості досягнуто ціною мінімального збільшення тривалості навчання та тестування. Це підтверджує високу обчислювальну ефективність архітектури, роблячи розроблену модель оптимальною за балансом між точністю розпізнавання та тривалістю виконання.

Також запропоновано програмно-апаратні рішення для практичного впровадження системи: використання Raspberry Pi або NVIDIA Jetson Nano з підключенням камер дозволяє забезпечити автономну роботу без потреби у хмарних ресурсах.

Відповідно до експертного оцінювання, ступінь новизни визначено як «відносно нова», що свідчить про наявність інноваційних елементів у постановці задачі та застосованих методах дослідження. Рівень теоретичного опрацювання роботи охарактеризовано як «Розробка способу (алгоритму, програми)», що підтверджує наявність чітко сформульованого підходу до вирішення поставленої проблеми та його практичну реалізацію. Запропонована технологія продемонструвала високий науковий рівень та підвищила точність класифікації до 98%, що перевищує результати існуючих аналогів.

Водночас проведене оцінювання комерційного потенціалу показало, що розробка має привабливість вище середнього (36 балів). Обчислений

комплексний показник ефективності ( $Kp > 1$ ) засвідчив доцільність реалізації проекту, а період окупності інвестицій, що становить 1,67 року (менше трьох років), підтвердив економічну доцільність і інвестиційну привабливість запропонованої технології. Це дає підстави стверджувати, що впровадження розробленої системи у практику аграрних підприємств може стати економічно вигідним рішенням і стимулювати розвиток галузі.

Таким чином, розроблена в межах магістерської кваліфікаційної роботи інформаційна інтелектуальна технологія класифікації зображень овочів і фруктів є ефективним інструментом для автоматизації процесів контролю якості та моніторингу стану продукції. Вона поєднує сучасні досягнення в галузі глибокого навчання та комп'ютерного зору, демонструє високу точність і стабільність роботи, має значний науковий і комерційний потенціал, а також відкриває перспективи для подальшого розвитку цифрових технологій у сільському господарстві.

## СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. Ярослав Смакота. Зберігання овочів і фруктів: методи та умови. 17 грудня 2024 року. [Електронний ресурс]. – URL: <https://agroapp.com.ua/uk/blog/zberigannya-ovochiv-i-fruktiv-metodi-ta-umovi/> (дата звернення: 23.09.2025).
2. Лісачов Р. В., Інформаційна інтелектуальна технологія класифікації зображень у сфері зберігання овочів та фруктів. *Матеріали Всеукраїнської науково-практичної інтернет-конференції «Молодь в науці: дослідження, проблеми, перспективи (МН-2026)»*. Вінниця, 2025. URL: <https://conferences.vntu.edu.ua/index.php/mn/mn2026/paper/view/25939> (дата звернення: 10.11.2025).
3. Наука про дані: машинне навчання та інтелектуальний аналіз даних: електронний навчальний посібник комбінованого (локального та мережевого) використання [Електронний ресурс] / В. Б. Мокін, М. В. Дратований – Вінниця: ВНТУ, 2024. – 258 с. URL: <https://docs.vntu.edu.ua/card.php?id=8163>. (дата звернення: 23.09.2025).
4. Fortune Business Insights. *Fruit and Vegetable Processing Market Size, Share, and Industry Analysis By Type (Fruits and Vegetables), By Product Type (Raw Fruits, Fresh Cuts, Canned, Frozen, and Dried & Dehydrated), By (Pre-processing, Washing, Filling, Seasoning, and Packaging), and Regional Forecast till 2032* [Електронний ресурс]. – URL: <https://www.fortunebusinessinsights.com/fruit-and-vegetable-processing-market-112720> (дата звернення: 09.10.2025).
5. Li, D., Bai, L., Wang, R., & Ying, S. (2024). Research Progress of Machine Learning in Extending and Regulating the Shelf Life of Fruits and Vegetables. *Foods*, 13(19), 3025. [Електронний ресурс] – Режим доступу: <https://doi.org/10.3390/foods13193025> (дата звернення: 09.11.2025).

6. Daza, A., Zavaleta Ramos, K., Arroyo Paz, A., & Mendoza Rivera, R. D. (2024). Deep Learning and Machine Learning for Plant and Fruit Recognition: A Systematic Review. *Journal of System and Management Sciences*, Vol. 14(No. 3). [Електронний ресурс]. URL: <https://www.aasmr.org/jsms/Vol14/No.3/Vol.14.No.3.14.pdf> (Дата звернення: 07.11.2025).
7. Dou, S. *Classification of Citrus Huanglongbing Degree Based on ...* (порівняння MobileNetV2 з InceptionV3, DenseNet121 та ін.). [Електронний ресурс]. 2023. URL: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC10303994/>. (Дата звернення: 09.10.2025).
8. Sanga, S., Mero, V., & Machuve, D. *Mobile-Based Deep Learning Models for Banana Diseases Detection*. arXiv. [Електронний ресурс]. – URL: <https://arxiv.org/pdf/2004.03718>. (Дата звернення: 07.10.2025).
9. Szegedy C., Vanhoucke V., Ioffe S., Shlens J., Wojna Z. Rethinking the Inception Architecture for Computer Vision. // *Proceedings of the IEEE CVPR*. 2016. URL: <https://arxiv.org/abs/1512.00567> (Дата звернення: 25.10.2025).
10. Rozan, M., Dwiyanti, M., & Muhammad, N. *Implementation and Testing of an IoT System Using Node-Red and OPC UA for Monitoring an Automated Storage Warehouse*. *Seminar Nasional Teknik Elektro*, 10(1), 183-188. – 2024. URL: <https://prosiding.pnj.ac.id/index.php/SNTE/article/view/2413> (Дата звернення: 09.10.2025)
11. Joopally, V., Kaundinya, A., & Rao, A. (). *Image Processing: Comparison and Analysis of Image Formats*. *IJRASET: Journal for Research in Applied Science and Engineering Technology*. – 2023. URL: <https://www.ijraset.com/research-paper/image-processing-comparison-and-analysis-of-image-formats> (Дата звернення: 09.10.2025).
12. Бібліотека Numpy. URL: <https://pythonworld.ru/numpy/1.html> (дата звернення: 02.09.2025)

13. Torres-Sánchez, R., López-García, B., & Gómez-García, J. (2020). *Real-Time Monitoring System for Shelf Life Estimation of Fruit and Vegetables*. *Sensors*. URL: <https://www.mdpi.com/1424-8220/20/7/1860> (Дата звернення: 09.10.2025).

14. Li, D., et al. (2024). *Research Progress of Machine Learning in Extending and Predicting Shelf Life of Fruits and Vegetables (review)*. *Foods*. URL: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC11475079/> (Дата звернення: 09.11.2025).

15. Balasubramanian, S. (). *OpenCV (C++ vs Python) vs MATLAB for Computer Vision*. LearnOpenCV. 2023. URL: <https://learnopencv.com/opencv-c-vs-python-vs-matlab-for-computer-vision/> (Дата звернення: 09.10.2025).

16. Lehtomaa, M. *Image Classification Using Deep Learning with Java* Bachelor's thesis, Bachelor of Engineering, Information and Communications Technology. Turku University of Applied Sciences. 2021. URL: [https://theseus.fi/bitstream/handle/10024/494349/Lehtomaa\\_Martin.pdf;jsessionid=50585AFACB148F7E46C82A0430ACDCAG?sequence=2](https://theseus.fi/bitstream/handle/10024/494349/Lehtomaa_Martin.pdf;jsessionid=50585AFACB148F7E46C82A0430ACDCAG?sequence=2). (Дата звернення: 07.10.2025).

17. AI-ML Mastery. (n.d.). *AI & ML with R & Python: Which Language is Better for Machine Learning?* URL: <https://ai-mlmastery.com/blog/ai-ml-r-vs-python> (дата звернення: 22.10.2025).

18. Google Colab — офіційний сайт. *Colab is a hosted Jupyter Notebook service ... provides free access to computing resources*. URL: <https://colab.google> (дата звернення: 09.11.2025).

19. Amazon. *Amazon SageMaker AI – сервіс для побудови, навчання та розгортання моделей машинного навчання у масштабі*. URL: <https://aws.amazon.com/sagemaker/>. (Дата звернення: 07.10.2025).

20. Microsoft. *Integrate Azure ML Model with Power BI by using Python*. *Microsoft Learn*, 2023. URL: <https://learn.microsoft.com/en-us/answers/questions/258899/integrate-azure-ml-model-with-power-bi-by-using-py>. (дата звернення: 29.10.2025).

21. IBM. *AutoML and AutoAI – IBM Watson Studio*. IBM Products, 2024. URL: <https://www.ibm.com/products/watson-studio/autoai> (дата звернення: 09.10.2025).
22. Anaconda. *Anaconda Documentation* — офіційна документація дистрибутива Anaconda, яка описує, як працює середовище, менеджер пакетів, інтеграція з Python/R тощо. URL: <https://www.anaconda.com/docs/mai> (дата звернення: 29.10.2025).
23. Kaggle. Kaggle Notebooks. *Kaggle Documentation*, 2024. URL: <https://www.kaggle.com/docs/notebooks>. (дата звернення: 09.10.2025).
24. Роман Лісачов. Classifications of fruit and vegetable images – версія ноутбука на Kaggle – 07.09.2025 р. [Електронний ресурс] URL: <https://www.kaggle.com/code/romanlisachov/classifications-of-fruit-and-vegetable-images> (Дата звернення: 30.10.2025).
25. Fruits 360 Dataset. Датасет на Kaggle. Версія: 2025.09.04.0. URL: <https://www.kaggle.com/datasets/moltean/fruits> (Дата звернення: 27.10.2025).
26. Fruit and Vegetable Disease (Healthy vs Rotten). Датасет на Kaggle. URL: <https://www.kaggle.com/datasets/muhammad0subhan/fruit-and-vegetable-disease-healthy-vs-rotten> (Дата звернення: 27.10.2025).
27. Fresh and Stale Images of Fruits and Vegetables. Датасет на Kaggle. URL: <https://www.kaggle.com/datasets/raghavrpotdar/fresh-and-stale-images-of-fruits-and-vegetables> (Дата звернення: 27.10.2025).
28. Kritik Seth. Fruits and Vegetables Image Recognition Dataset – версія датасета на Kaggle – 2022 р. [Електронний ресурс] URL: <https://www.kaggle.com/datasets/kritikseth/fruit-and-vegetable-image-recognition>, (Дата звернення: 30.10.2025).
29. Shubham Chauhan. Transfer\_Learning\_With\_MobileNetv2 – версія ноутбука на Kaggle – 24.06.2023 р. [Електронний ресурс] URL: <https://www.kaggle.com/code/shubham219/transfer-learning-with-mobilenetv2> (Дата звернення: 30.10.2025).

30. Kyeremeh Bright. (2022). *Fruit and Vegetable Classification*. Kaggle. URL: <https://www.kaggle.com/code/kyeremehbright/fruit-and-vegetable-classification>. (Дата звернення: 07.10.2025).
31. Akasha, M., Honnappa Harikantra, S., Thrupthi, P. R., Anappa Alur, V., & Hegde, S.. *IoT Based Fruits and Vegetables Storage Monitoring and Machine Learning Based Shelf-Life and Disease Detection System. International Journal of Creative Research Thoughts (IJCRT)*. – 2023. [Електронний ресурс] – Режим доступу: <https://ijcrt.org/papers/IJCRTX020015.pdf>.
32. Методичні вказівки до виконання економічної частини магістерських кваліфікаційних робіт / Уклад. : В. О. Козловський, О. Й. Лесько, В. В. Кавецький. – Вінниця : ВНТУ, 2021. – 42 с.
33. Кавецький В. В., Козловський В. О., Причепя І. В. Економічне обґрунтування інноваційних рішень: практикум. Вінниця : ВНТУ, 2016. 113 с.

## Додаток А

Міністерство освіти і науки України  
Вінницький національний технічний університет  
Факультет інтелектуальних інформаційних технологій та автоматизації

ЗАТВЕРДЖУЮ

Завідувач кафедри САІТ

\_\_\_\_\_ д.т.н., проф. Віталій МОКІН

« \_\_\_\_ » \_\_\_\_\_ 2025 р.

## ТЕХНІЧНЕ ЗАВДАННЯ

на магістерську кваліфікаційну роботу

«ІНФОРМАЦІЙНА ІНТЕЛЕКТУАЛЬНА ТЕХНОЛОГІЯ КЛАСИФІКАЦІЇ  
ЗОБРАЖЕНЬ У СФЕРІ ЗБЕРІГАННЯ ОВОЧІВ ТА ФРУКТІВ»

08-34.МКР.002.00.000 ТЗ

Керівник: д.т.н., проф., зав. каф. САІТ

\_\_\_\_\_ Віталій МОКІН

« \_\_\_\_ » \_\_\_\_\_ 2025 р.

Розробив: студент гр. 2ІСТ-24м

\_\_\_\_\_ Роман ЛІСАЧОВ

« \_\_\_\_ » \_\_\_\_\_ 2025 р.

м. Вінниця 2025 рік

### 1. Підстава для проведення робіт.

Підставою для виконання роботи є наказ №\_\_ по ВНТУ від «\_\_» \_\_\_\_\_ 2025р., та індивідуальне завдання на МКР, затверджене протоколом №\_\_ засідання кафедри САІТ від «\_\_» \_\_\_\_\_ 2025р.м

### 2. Джерела розробки:

1) Наука про дані: машинне навчання та інтелектуальний аналіз даних: електронний навчальний посібник комбінованого (локального та мережевого) використання [Електронний ресурс] / В. Б. Мокін, М. В. Дратований – Вінниця: ВНТУ, 2024. – 258 с. URL: <https://docs.vntu.edu.ua/card.php?id=8163>. (Дата звернення: 11.09.2025).

2) Kyeremeh Bright. *Fruit and Vegetable Classification*. Kaggle. – 2022. URL: <https://www.kaggle.com/code/kyeremehbright/fruit-and-vegetable-classification>. (Дата звернення: 07.10.2025).

3) Daza, A., Zavaleta Ramos, K., Arroyo Paz, A., & Mendoza Rivera, R. D. *Deep Learning and Machine Learning for Plant and Fruit Recognition: A Systematic Review*. *Journal of System and Management Sciences*, 14(3), 226–246. – 2024. URL: <https://doi.org/10.33168/JSMS.2024.0314>. (Дата звернення: 07.10.2025).

### 3. Мета і призначення роботи.

Метою кваліфікаційної роботи є підвищення точності та ефективності класифікації зображень овочів та фруктів шляхом розроблення інформаційної інтелектуальної технології.

### 4. Вихідні дані для проведення робіт.

Kaggle Dataset «Fruits and Vegetables Image Recognition»

<https://www.kaggle.com/datasets/kritikseth/fruit-and-vegetable-image-recognition>

### 5.Методи дослідження:

У дослідженнях використовуються методи розвідувального аналізу, побудови моделей машинного навчання та методи статистичного аналізу даних для оптимізації параметрів моделей та оцінки їх точності.

### 6. Етапи роботи і терміни їх виконання:

- а) Аналіз предметної області \_\_\_\_\_ – \_\_\_\_\_
- б) Вибір оптимальних інформаційних технологій \_\_\_\_\_ – \_\_\_\_\_
- в) Розроблення інформаційної технології \_\_\_\_\_ – \_\_\_\_\_
- г) Тренування та тестування моделей машинного навчання \_\_\_\_\_ – \_\_\_\_\_
- д) Економічна частина \_\_\_\_\_ – \_\_\_\_\_
- е) Оформлення матеріалів до захисту МКР \_\_\_\_\_ – \_\_\_\_\_

7. Очікувані результати та порядок реалізації.

Підвищенні точності та ефективності класифікації зображень овочів та фруктів, завдяки розробленій інформаційній інтелектуальній технології для впровадження автоматизованих систем сортування продуктів.

8. Вимоги до розробленої документації.

Текстова та ілюстративна частини роботи оформлені у відповідності до вимог «Методичних вказівок до виконання магістерських кваліфікаційних робіт для студентів спеціальності 126 «Інформаційні системи та технології» (освітня програма «Інформаційні технології аналізу даних та зображень»).

9. Порядок приймання роботи.

- Публічний захист «\_\_» \_\_\_\_\_ 2025 р.
- Початок розробки «\_\_» \_\_\_\_\_ 2025 р.
- Граничні терміни виконання МКР «\_\_» \_\_\_\_\_ 2025 р.

Розробив студент групи 2ІСТ-24м \_\_\_\_\_ Роман ЛІСАЧОВ

## Додаток Б

**ПРОТОКОЛ ПЕРЕВІРКИ КВАЛІФІКАЦІЙНОЇ РОБОТИ**

Назва роботи: «Інформаційна інтелектуальна технологія класифікації зображень у сфері зберігання овочів та фруктів»

Тип роботи: магістерська кваліфікаційна робота

Підрозділ: кафедра САІТ, ФІІТА, гр. 2ІСТ-24м

Коефіцієнт подібності текстових запозичень, виявлених у роботі системою StrikePlagiarism 0,74%

Висновок щодо перевірки кваліфікаційної роботи (відмітити потрібне):

• Запозичення, виявлені у роботі, є законними і не містять ознак плагіату, фабрикації, фальсифікації. Роботу прийняти до захисту.

о У роботі не виявлено ознак плагіату, фабрикації, фальсифікації, але надмірна кількість текстових запозичень та/або наявність типових розрахунків не дозволяють прийняти рішення про оригінальність та самостійність її виконання. Роботу направити на доопрацювання.

о У роботі виявлено ознаки плагіату та/або текстових маніпуляцій як спроб укриття плагіату, фабрикації, фальсифікації, що суперечить вимогам законодавства та нормам академічної доброчесності. Робота до захисту не приймається.

Експертна комісія:

Віталій МОКІН, зав. каф. САІТ

\_\_\_\_\_ (підпис)

Сергій ЖУКОВ, доц. каф. САІТ

\_\_\_\_\_ (підпис)

Особа, відповідальна за перевірку \_\_\_\_\_ Сергій ЖУКОВ  
(підпис)

З висновком експертної комісії ознайомлений

Керівник \_\_\_\_\_  
(підпис)

Віталій МОКІН, зав. каф. САІТ, проф.

Здобувач \_\_\_\_\_  
(підпис)

Роман ЛІСАЧОВ

## Додаток В

## Лістинг програми

```
from tensorflow.keras.applications import MobileNetV2
from tensorflow.keras.preprocessing.image import ImageDataGenerator
from tensorflow.keras import layers, models, optimizers, regularizers
from tensorflow.keras.callbacks import ModelCheckpoint, EarlyStopping,
ReduceLROnPlateau

import tensorflow as tf
import matplotlib.pyplot as plt
import seaborn as sns
from sklearn.metrics import confusion_matrix, classification_report
import os
import numpy as np

from termcolor import colored
from tensorflow.keras import optimizers

import plotly.graph_objs as go
import plotly.figure_factory as ff
from plotly import tools
from plotly.offline import download_plotlyjs, init_notebook_mode, plot, iplot
init_notebook_mode(connected=True)

from sklearn.model_selection import train_test_split
from sklearn.metrics import confusion_matrix, accuracy_score

from sklearn.metrics import classification_report, confusion_matrix
from tensorflow.keras.preprocessing import image_dataset_from_directory

import cv2
from tensorflow.keras import layers, models
from scipy.io import loadmat
from keras.utils import to_categorical
import itertools
from tensorflow.keras.applications import EfficientNetB0
import pandas as pd
from tensorflow.keras.preprocessing.image import ImageDataGenerator
from tensorflow.keras.models import Sequential
```

```
from tensorflow.keras.layers import Conv2D, MaxPooling2D, Flatten, Dense,
Dropout
```

```
from tensorflow.keras.layers import BatchNormalization,
GlobalAveragePooling2D, Activation
from tensorflow.keras.regularizers import l2
from tensorflow.keras.utils import plot_model
```

```
from tensorflow.keras.optimizers import Adam
import warnings
warnings.filterwarnings("ignore")
```

```
# 3. Custom CNN
```

```
from tensorflow.keras import regularizers, layers, models
model = models.Sequential([
    layers.Conv2D(32, (3, 3), activation='relu', padding='same',
        kernel_regularizer=regularizers.l2(0.001),
        input_shape=(224, 224, 3)),
    layers.BatchNormalization(),
    layers.MaxPooling2D((2, 2)),
    layers.Conv2D(64, (3, 3), activation='relu', padding='same',
        kernel_regularizer=regularizers.l2(0.001)),
    layers.BatchNormalization(),
    layers.MaxPooling2D((2, 2)),
    layers.Conv2D(128, (3, 3), activation='relu', padding='same',
        kernel_regularizer=regularizers.l2(0.001)),
    layers.BatchNormalization(),
    layers.MaxPooling2D((2, 2)),
    layers.Dropout(0.3),
    layers.GlobalAveragePooling2D(),
    layers.Dense(256, activation='relu',
        kernel_regularizer=regularizers.l2(0.001)),
    layers.BatchNormalization(),
    layers.Dropout(0.4),
    layers.Dense(36, activation='softmax',
        kernel_regularizer=regularizers.l2(0.001))
])
model.compile(
    optimizer='adam',
    loss='sparse_categorical_crossentropy',
    metrics=['accuracy']
)
model.summary()
```

```

early_stop = EarlyStopping(
    monitor='val_loss',
    patience=5,
    restore_best_weights=True
)
reduce_lr = ReduceLROnPlateau(
    monitor='val_loss',
    factor=0.5,
    patience=3,
    min_lr=1e-6
)
callbacks = [early_stop, reduce_lr]

```

```

history = model.fit(
    train_dataset,
    epochs=150,
    validation_data=val_dataset,
    callbacks=callbacks,
    verbose=1
)

```

#### # 4. MobileNetV2

```

pre_trained_model = MobileNetV2(
    input_shape=(224, 224, 3),
    include_top=False,
    weights='imagenet',
    pooling=None
)

pre_trained_model.trainable = True
set_trainable = False
for layer in pre_trained_model.layers:
    if layer.name == 'block_16_expand':
        set_trainable = True
        layer.trainable = set_trainable

model = models.Sequential([
    pre_trained_model,
    layers.GlobalAveragePooling2D(),
    layers.BatchNormalization(),

```

```

layers.Dense(256, activation='relu', kernel_regularizer=regularizers.l2(0.001)),
layers.Dropout(0.4),
layers.Dense(128, activation='relu'),
layers.BatchNormalization(),
layers.Dropout(0.3),
layers.Dense(36, activation='softmax') # замінити на свою кількість класів
])
model.compile(
    optimizer=optimizers.Adam(learning_rate=0.0005),
    loss='categorical_crossentropy',
    metrics=['accuracy']
)

```

### # 5. EfficientNetB0

```

from tensorflow.keras.applications import EfficientNetB0
def build_efficientnet_b0(num_classes=36):
    base_model = EfficientNetB0(
        weights="imagenet",
        include_top=False,
        input_shape=(224, 224, 3)
    )
    base_model.trainable = False

    model = models.Sequential([
        base_model,
        layers.GlobalAveragePooling2D(),
        layers.Dropout(0.3), # трохи менший Dropout
        layers.Dense(256, activation="relu",
            kernel_regularizer=regularizers.l2(1e-4)),
        layers.BatchNormalization(),
        layers.Dropout(0.3),
        layers.Dense(num_classes, activation="softmax")
    ])
    return model
model = build_efficientnet_b0(num_classes=36)
model.compile(
    optimizer=tf.keras.optimizers.Adam(learning_rate=1e-3),
    loss="sparse_categorical_crossentropy",
    metrics=["accuracy"]
)

```

Додаток Г

## **ІЛЮСТРАТИВНА ЧАСТИНА**

**ІНФОРМАЦІЙНА ІНТЕЛЕКТУАЛЬНА ТЕХНОЛОГІЯ КЛАСИФІКАЦІЇ  
ЗОБРАЖЕНЬ У СФЕРІ ЗБЕРІГАННЯ ОВОЧІВ ТА ФРУКТІВ**

Нормоконтроль: к.т.н., доцент

\_\_\_\_\_ Сергій ЖУКОВ

«\_\_» \_\_\_\_\_ 2025 р.

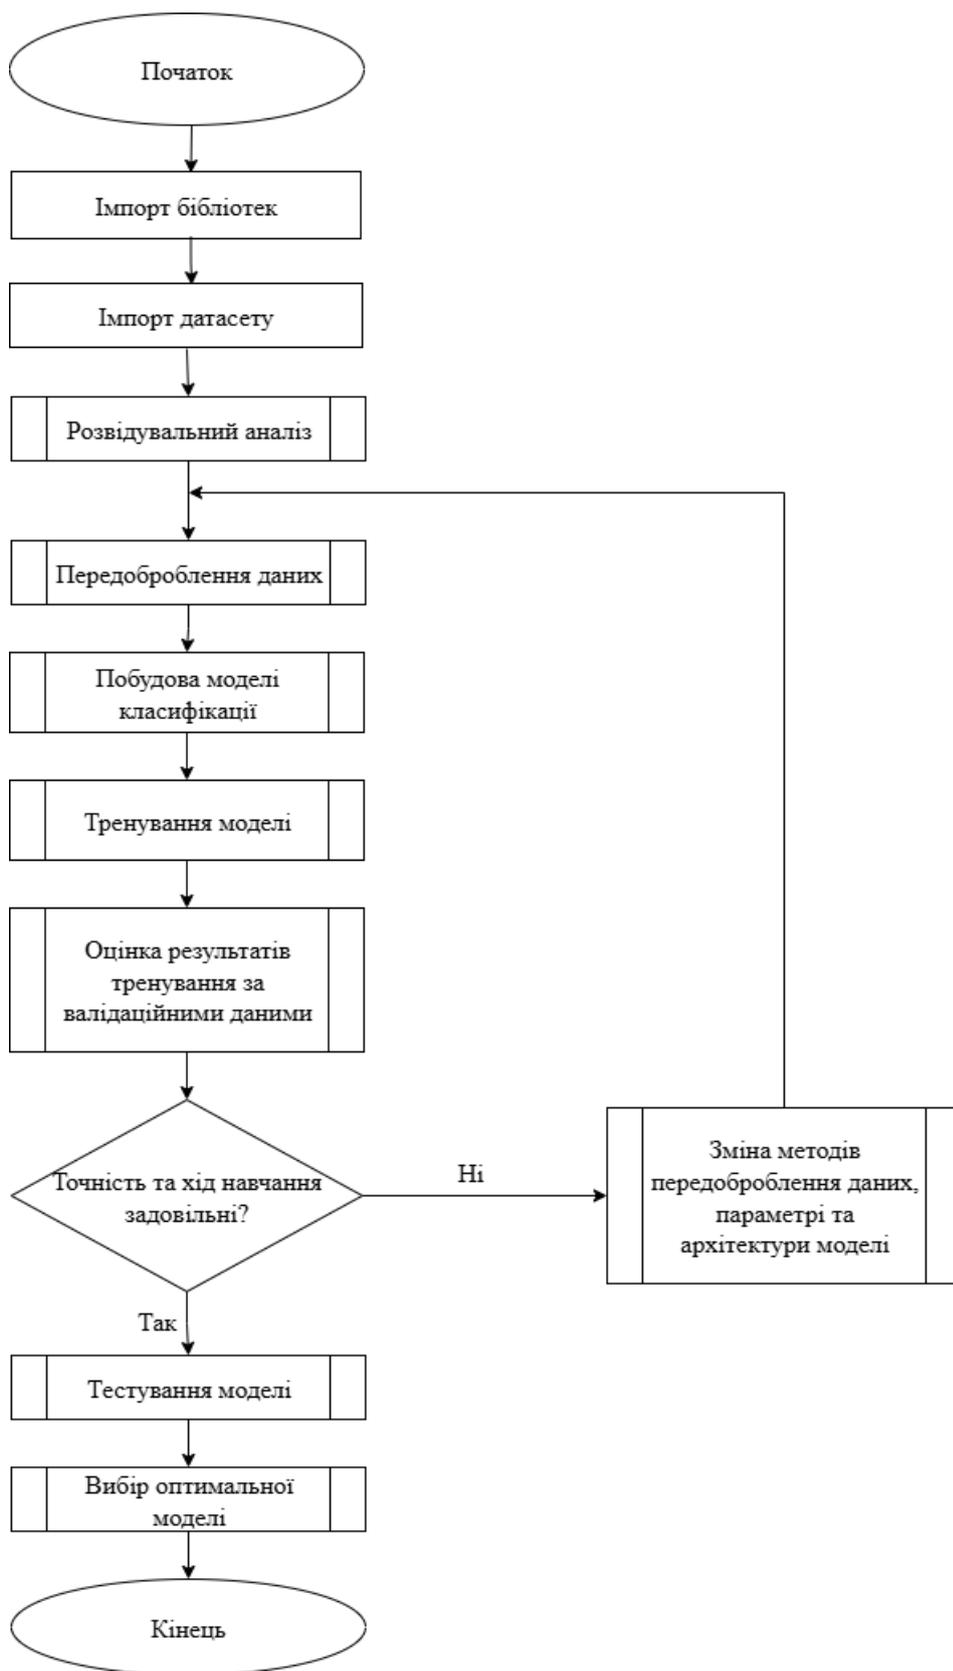


Рисунок Г.1 - Блок-схема алгоритму розроблення та дослідження моделей

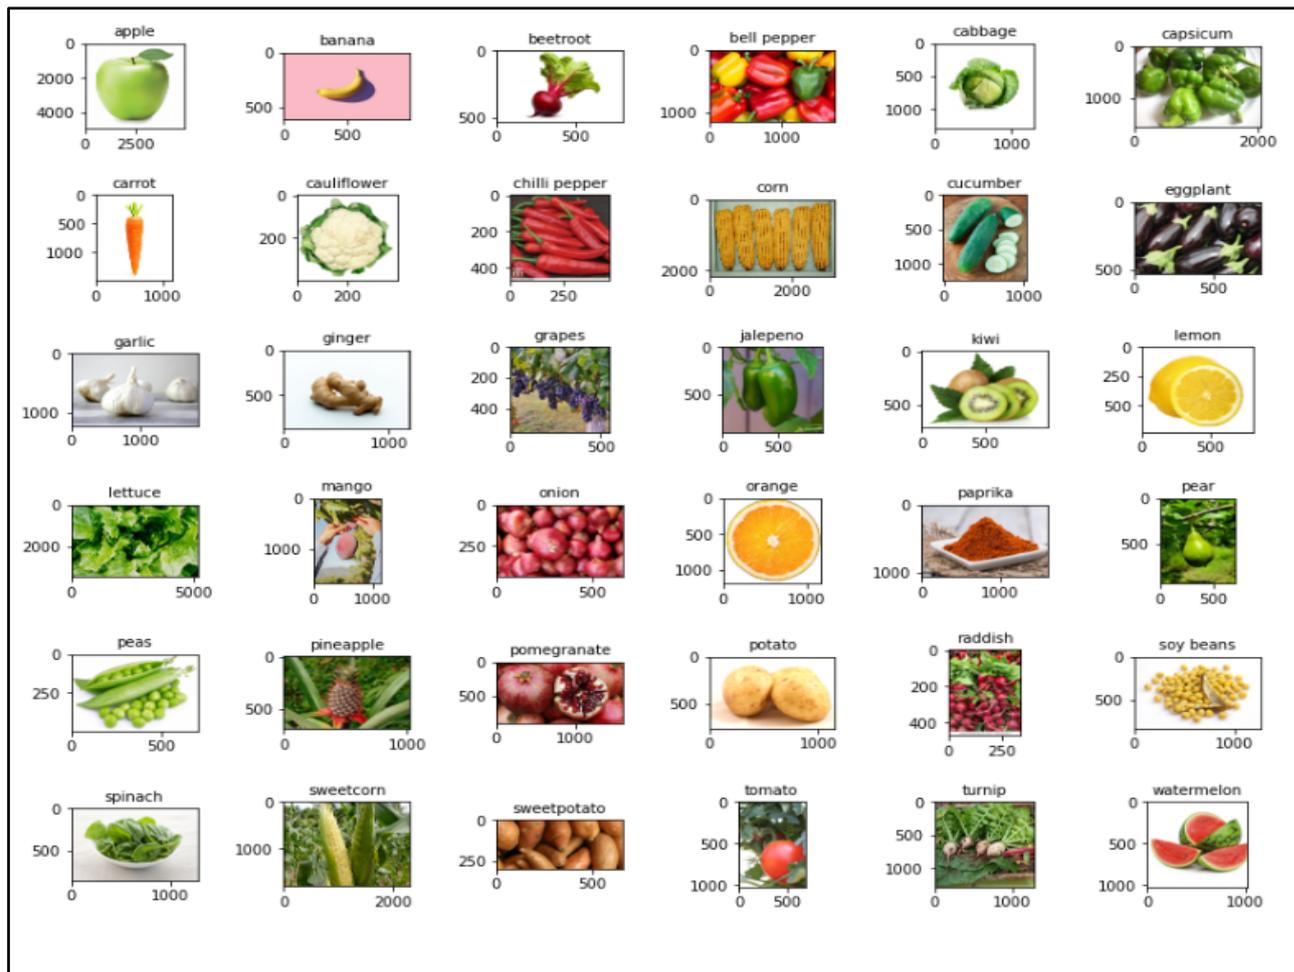
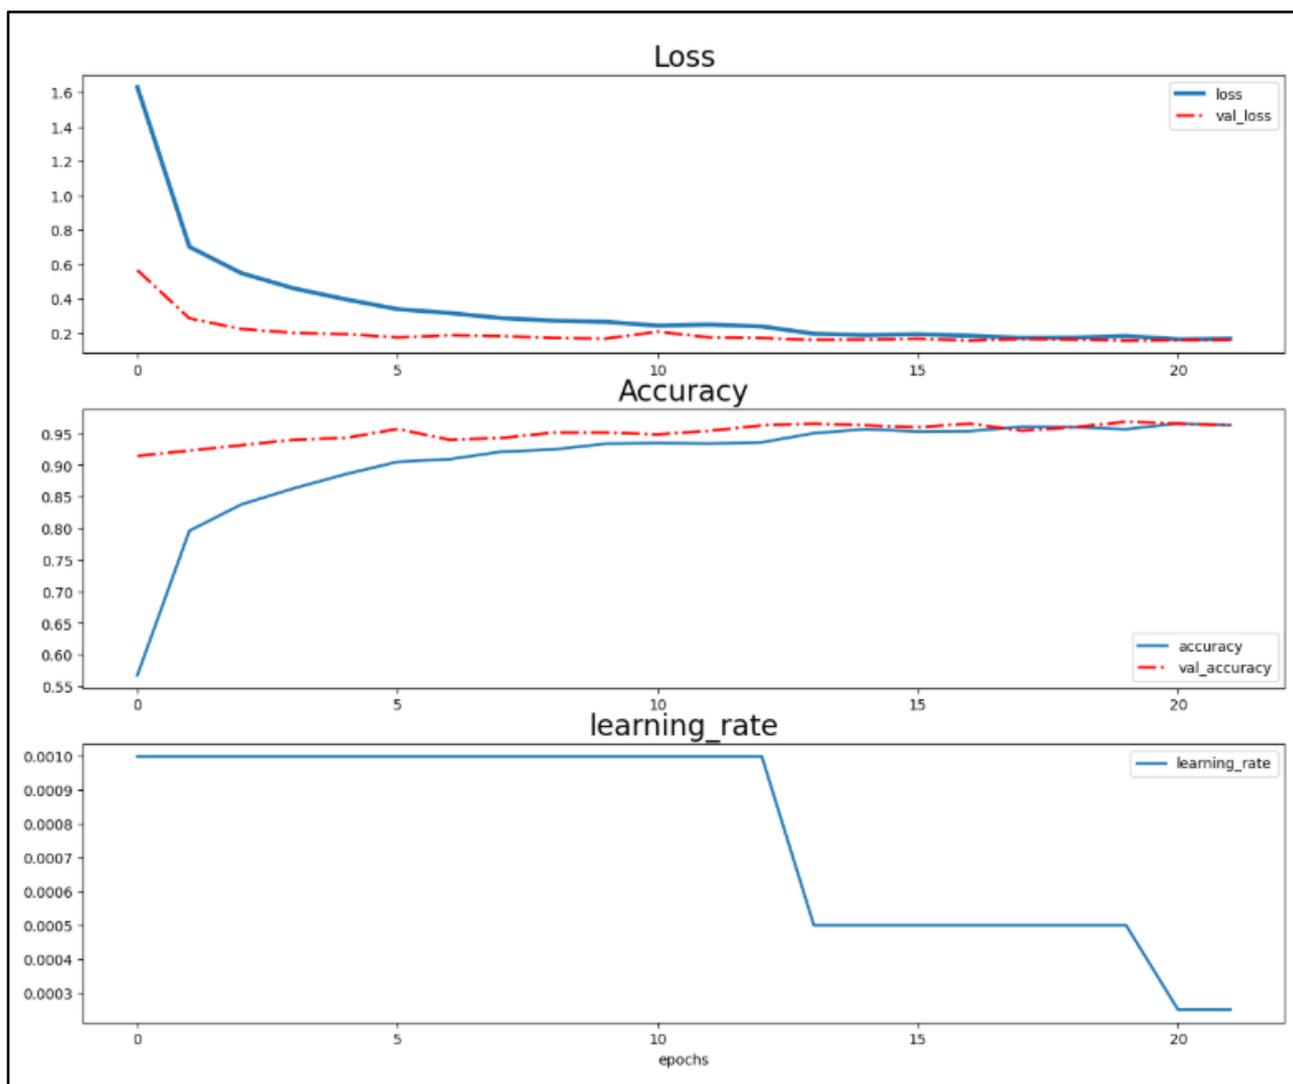


Рисунок Г.2 – Фрагмент датасету, який використано для випробування моделей

| Layer (type)   | Output Shape       | Param #   |
|--|--------------------|-----------|
| efficientnetb0 (Functional)                            | (None, 7, 7, 1280) | 4,049,571 |
| global_average_pooling2d_3<br>(GlobalAveragePooling2D) | (None, 1280)       | 0         |
| dropout_5 (Dropout)                                    | (None, 1280)       | 0         |
| dense_6 (Dense)  | (None, 256)        | 327,936   |
| batch_normalization_6<br>(BatchNormalization)          | (None, 256)        | 1,024     |
| dropout_6 (Dropout)                                    | (None, 256)        | 0         |
| dense_7 (Dense)  | (None, 36)         | 9,252     |

Рисунок Г.3 – Архітектура оптимальної моделі глибокого навчання

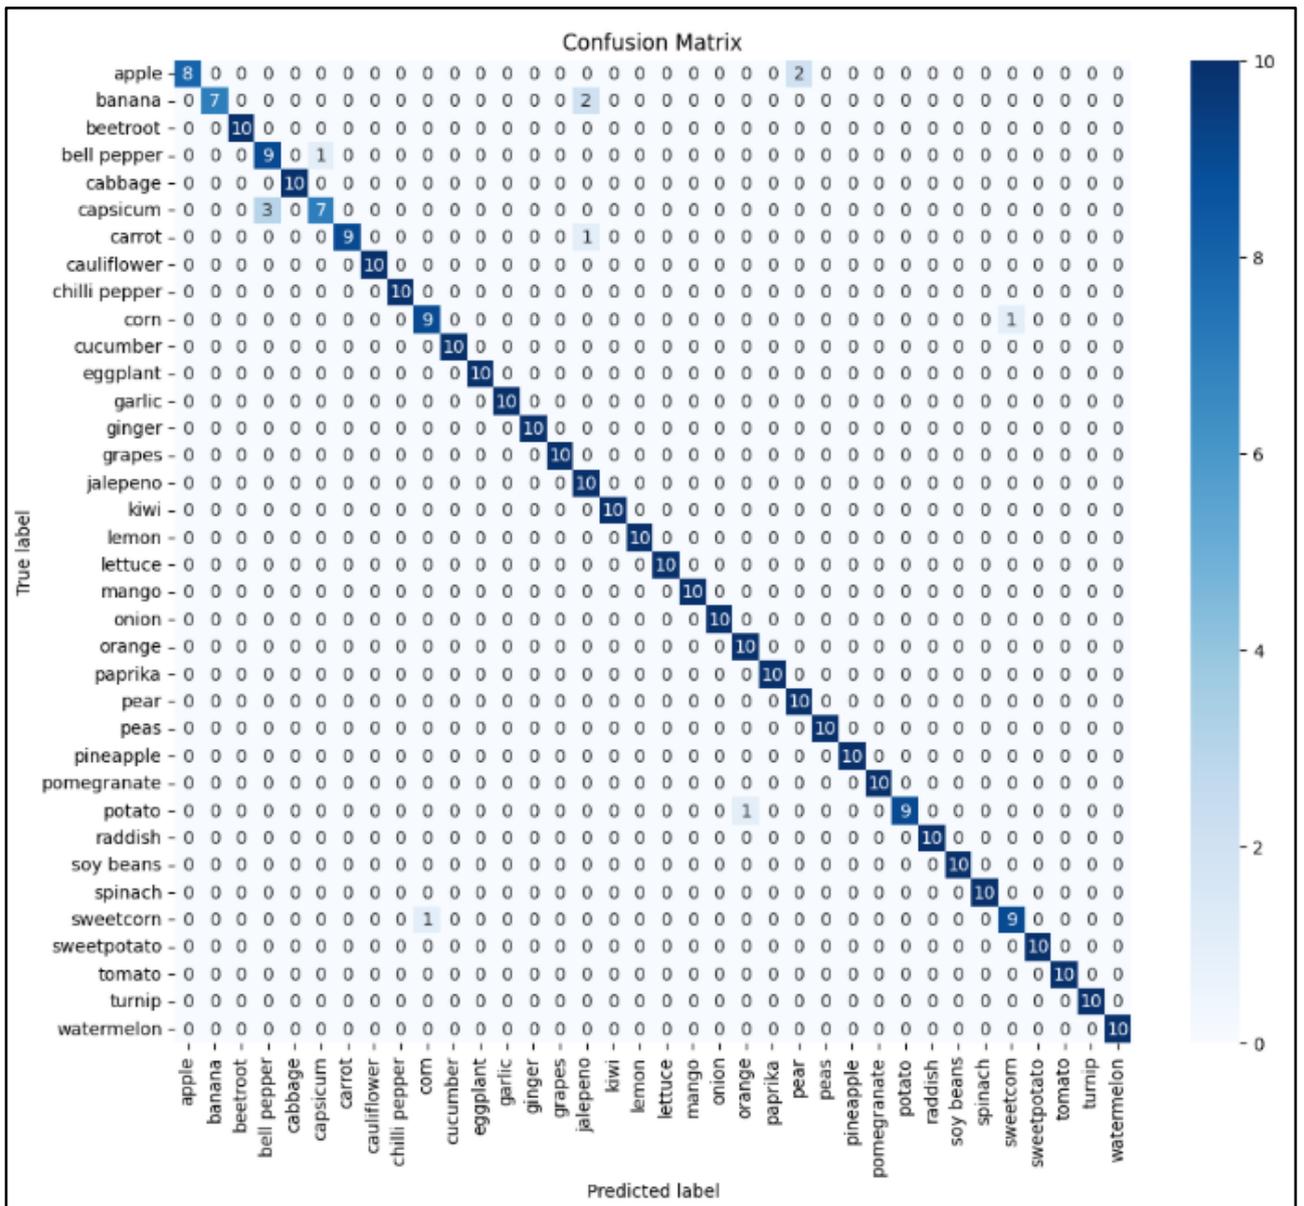


```

Best train accuracy: 0.9660 epoch 21
Best val accuracy:   0.9687 epoch 20
Best train loss:     0.1637 epoch 21
Best val loss:       0.1558 epoch 17

```

Рисунок Г.4 – Графіки результатів тренувань оптимальної інтелектуальної моделі



**Test Loss: 0.1538408249616623**  
**Test Accuracy: 0.9665738344192505**

Рисунок Г.5 – Конфузійна матриця роботи оптимальної інтелектуальної моделі

Таблиця Г.1 – Порівняння параметрів та результатів роботи моделей

| <b>Model</b>       | <b>Total<br/>params</b> | <b>Test<br/>accuracy</b> | <b>Test<br/>Loss</b> | <b>Train<br/>accurac<br/>y</b> | <b>Val<br/>accuracy</b> | <b>Trainin<br/>g time</b> | <b>Testing<br/>time</b> |
|--------------------|-------------------------|--------------------------|----------------------|--------------------------------|-------------------------|---------------------------|-------------------------|
| Custom<br>CNN      | 137,444<br>(536.9KB)    | 0.95                     | 0.55                 | 0.84                           | 0.95                    | 23m 27s                   | 4s                      |
| MobileNetV2        | 2,629,092<br>(10.03MB)  | 0.98                     | 0.19                 | 0.99                           | 0.98                    | 1 h 11m<br>and 20s        | 22s                     |
| Efficient<br>NetB0 | 4,387,783<br>(16.74MB)  | 0.97                     | 0.15                 | 0.97                           | 0.97                    | 12m 18s                   | 16s                     |

Таблиця Г.2 – Порівняння результатів роботи розробленої моделі з аналогом

| <b>Model</b>                         | <b>Total params</b> | <b>Test accuracy</b> | <b>Test Loss</b> | <b>Train accuracy</b> | <b>Val accuracy</b> | <b>Training time</b> | <b>Testing time</b> |
|--------------------------------------|---------------------|----------------------|------------------|-----------------------|---------------------|----------------------|---------------------|
| Розроблена, на основі EfficientNetB0 | 4,387,783 (16.74MB) | 0.97                 | 0.15             | 0.97                  | 0.97                | 12 m18 s             | 16s                 |
| Аналог, на основі MobileNetV2        | 2,629,092 (10.03MB) | 0.94                 | 0.2              | 0.96                  | 0.96                | 11m 45s              | 14s                 |

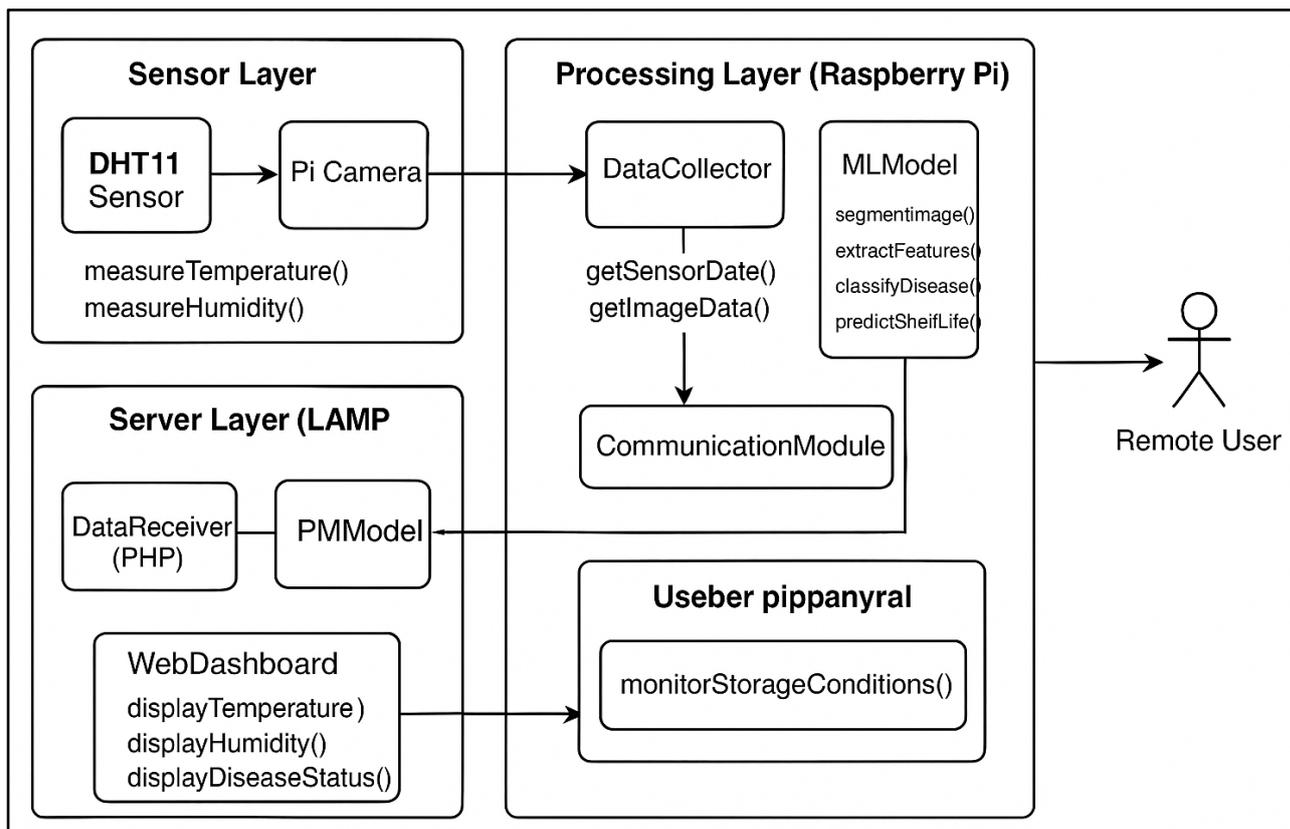


Рисунок Г.6 – UML-діаграма компонентів системи моніторингу зберігання фруктів і овочів на основі Інтернету речей