



## КВАЛІФІКАЦІЙНА РОБОТА БАКАЛАВРА

на тему Метод нейромережевої ідентифікації стадій зрілості плодів  
полуниці за зображеннями для автономних тепличних комплексів


Галузь знань 12 – Інформаційні технології  
Шифр і назва галузі знань  
Спеціальність 122 – Комп'ютерні науки  
Шифр і назва спеціальності  
Освітня програма Комп'ютерні науки  
Назва освітньої програми

Виконав: студент групи КН-22-3  Артур ФІЛПОВ  
Група виконавця Підпис Ім'я, ПРІЗВИЩЕ

Керівник: ст. викл. каф. КН  Тетяна СКРИПНИК  
Науковий ступінь, посада Підпис Ім'я, ПРІЗВИЩЕ

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


До захисту допускаю:

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

18 червня 2026 р.

Львівський національний університет  
Факультет інформаційних технологій  
Кафедра комп'ютерних наук  
Освітній ступінь бакалавр  
Галузь знань 12 – Інформаційні технології  
Спеціальність 122 – Комп'ютерні науки

ЗАТВЕРДЖУЮ  
Завідувач кафедри комп'ютерних наук

  
(підпис)  
д.т.н., професор Олександр БАРМАК  
« 22 » лютого 2026 року

### ЗАВДАННЯ НА КВАЛІФІКАЦІЙНУ РОБОТУ БАКАЛАВРА

1. Тема кваліфікаційної роботи бакалавра: «Метод нейромережевої ідентифікації стадій зрілості плодів полуниці за зображеннями для автономних тепличних комплексів».

2. Завдання видано студенту Артуру Філіпову  
(Ім'я, прізвище)

3. Керівник роботи старший викладач кафедри КН Тетяна Скрипник  
(посада, ім'я, прізвище)

4. Затверджено наказом університету від «20» лютого 2026 р. № 7

5. Дата видачі завдання студенту: «22» лютого 2026 р.

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

Мета роботи полягає в підвищенні повноти визначення стадій зрілості плодів полуниці за RGB-зображеннями в умовах тепличного середовища. Для досягнення мети слід виконати такі задачі: провести огляд та аналіз сучасних інформаційних моделей, методів комп'ютерного зору та моделей глибокого навчання; формалізувати задачу нейромережевого виявлення та ідентифікації стадій зрілості плодів полуниці; розробити метод нейромережевого виявлення та класифікації плодів полуниці орієнтований на підвищення повноти ідентифікації стадій зрілості; реалізувати програмний засіб та провести експериментальне дослідження розробленого методу з оцінюванням якості виявлення та ідентифікації стадій зрілості плодів полуниці.

7. Календарний план виконання кваліфікаційної роботи бакалавра:

№	Назва етапів (розділів) кваліфікаційної роботи бакалавра	Термін виконання	Прим
1	Вибір напрямку дослідження та узгодження теми кваліфікаційної роботи з керівником, складання календарного графіка виконання	січень 2026	
2	Ознайомлення з предметною областю, формулювання мети і задач дослідження, визначення об'єкта та предмета дослідження	лютий 2026	
3	Проектування методу розв'язання задачі, опис архітектурних рішень, розроблення математичних моделей та алгоритмів.	березень 2026	
4	Обґрунтування інструментарію розробки, програмна реалізація розробленого методу, проведення експериментального тестування та оцінювання ефективності.	квітень 2026	
5	Написання тексту кваліфікаційної роботи, урахування зауважень керівника, оформлення згідно з вимогами	травень 2026	
6	Розроблення презентаційних матеріалів та попередній захист кваліфікаційної роботи	травень 2026	
7	Отримання відгуку керівника, рецензії, перевірка тексту кваліфікаційної роботи на плагіат, нормоконтроль	червень 2026	
8	Підготовка до захисту та захист кваліфікаційної роботи	червень 2026	

Виконавець: студент групи КН-22-3

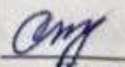
Група виконавця

  
Підпис

Артур ФІЛІПОВ  
Ім'я, ПРІЗВИЩЕ

Керівник: ст. викл. каф. КН

Науковий ступінь, посада

  
Підпис

Тетяна СКРИПНИК  
Ім'я, ПРІЗВИЩЕ

## Анотація

Тема кваліфікаційної роботи бакалавра: «Метод нейромережевої ідентифікації стадій зрілості плодів полуниці за зображеннями для автономних тепличних комплексів»

Виконавець кваліфікаційної роботи бакалавра: студент групи КН-22-3 Артур Філіпов

Керівник кваліфікаційної роботи бакалавра: старший викладач кафедри КН Тетяна Скрипник


Кваліфікаційна робота бакалавра містить:

Пояснювальна записка				Кількість додатків
Сторінок	Рисунків	Таблиць	Джерел інформації	
57	14	6	43	2

Метою кваліфікаційної роботи бакалавра є підвищення повноти визначення стадій зрілості плодів полуниці за RGB-зображеннями в умовах тепличного середовища. Для розробки було використано мову програмування Python, модель детекції YOLO11n, засоби комп'ютерного зору та фрагментований SANN-інференс для покращення виявлення дрібних і частково перекритих плодів. Розроблена система призначена для автоматизованого виявлення плодів полуниці, визначення їхньої стадії зрілості та формування аналітичної інформації для підтримки рішення щодо збору врожаю.

Напрямами практичного використання розробленої системи є тепличне вирощування полуниці, автоматизований агротехнічний моніторинг, підтримка прийняття рішень щодо збору врожаю, а також інтеграція в автономні або напівавтономні тепличні комплекси.

Ключові слова: полуниця, стадія зрілості, RGB-зображення, комп'ютерний зір, YOLO, SANN, нейромережева детекція, тепличний моніторинг.

Виконавець: студент групи КН-22-3  Артур ФІЛІПОВ  
Група виконавця Підпис Ім'я, ПРІЗВИЩЕ

## Зміст

Перелік скорочень .....	3
Вступ.....	5
Розділ 1 Характеристика предметної області: аналіз моделей, методів та реалізацій.....	8
1.1 Аналіз інформаційних моделей.....	8
1.2 Огляд моделей глибокого навчання для задач детекції об'єктів.....	11
1.3 Огляд теоретичних підходів до розв'язання задачі визначення зрілості .....	15
1.4 Мета та завдання роботи .....	17
Розділ 2 Метод нейромережевої ідентифікації стадій зрілості плодів полуниці	18
2.1 Формалізація задачі детекції та класифікації стадій зрілості.....	18
2.2 Детекція об'єктів за допомогою нейромережі YOLO.....	20
2.3 Фрагментований інференс для детекції дрібних плодів .....	22
2.4 Опис набору даних та підготовка.....	25
2.5 Метрики оцінювання .....	26
2.6 Сценарій експериментального дослідження .....	27
2.7 Висновки до розділу 2 .....	28
Розділ 3 Експериментальне дослідження методу .....	30
3.1 Опис застосування та архітектура системи нейромережевої ідентифікації стадій зрілості плодів полуниці.....	30
3.2 Аналіз результатів навчання та тестування YOLO-моделі .....	36
3.3 Обмеження методу та напрямки вдосконалення .....	44
3.4 Висновки до розділу 3 .....	46
Загальні висновки.....	48
Перелік посилань.....	50
Додатки	

## Перелік скорочень

Скорочення, термін, позначення	Пояснення
AP	Average Precision, середня точність для окремого класу
AR	Augmented Reality, доповнена реальність
BCE	Binary Cross-Entropy, бінарна перехресна ентропія
bbox	Bounding box, прямокутна обмежувальна рамка об'єкта
C2f	Cross Stage Partial with 2 Convolutions, блок архітектури YOLO
CBS	Convolution + Batch Normalization + SiLU, згортковий блок YOLO
CIoU	Complete Intersection over Union, модифікована метрика перекриття рамок
CNN	Convolutional Neural Network, згорткова нейронна мережа
CPU	Central Processing Unit, центральний процесор
CUDA	Compute Unified Device Architecture, платформа паралельних обчислень NVIDIA
Det	Detection, кількість сформованих детекцій
DFL	Distribution Focal Loss, функція втрат для уточнення координат рамки
FN	False Negative, хибно негативний результат
FP	False Positive, хибно позитивний результат
FPN	Feature Pyramid Network, мережа піраміди ознак
FPS	Frames Per Second, кількість кадрів за секунду
GT	Ground Truth, еталонна розмітка
GPU	Graphics Processing Unit, графічний процесор
HSV	Hue, Saturation, Value, колірний простір тон–насиченість–значення

IoU	Intersection over Union, коефіцієнт перекриття передбаченої та еталонної рамок
mAP	mean Average Precision, середня усереднена точність
NMS	Non-Maximum Suppression, алгоритм придушення немаксимумів
PAN	Path Aggregation Network, мережа агрегації ознак
PNG	Portable Network Graphics, формат графічного файлу
PR-крива	Precision-Recall curve, крива залежності точності від повноти
RGB	Red, Green, Blue, колірна модель червоний–зелений–синій
R-CNN	Region-based Convolutional Neural Network, регіональна згорткова нейронна мережа
SAHI	Slicing Aided Hyper Inference, фрагментований інференс із нарізкою зображення
SPPF	Spatial Pyramid Pooling Fast, блок швидкого просторового пірамідального пулінгу
SSD	Single Shot MultiBox Detector, одностадійний детектор об'єктів
TP	True Positive, істинно позитивний результат
WBF	Weighted Box Fusion, зважене об'єднання обмежувальних рамок
YOLO	You Only Look Once, сімейство одностадійних моделей детекції об'єктів
YOLO11n	компактна версія моделі YOLO11 nano
YAML	Yet Another Markup Language, формат конфігураційного файлу
ZIP	формат архівного файлу

## Вступ

Метою кваліфікаційної роботи бакалавра є підвищення повноти визначення стадій зрілості плодів полуниці за RGB-зображеннями в умовах тепличного середовища шляхом розроблення методу нейромережевої ідентифікації стадій зрілості плодів полуниці за зображеннями на основі донавченої YOLO-моделі, що забезпечує автоматичну локалізацію плодів, визначення їхньої стадії зрілості та формування аналітичної інформації для прийняття рішення щодо збору врожаю.

**Актуальність.** Полуниця садова є однією з економічно значущих ягідних культур, а її вирощування в умовах тепличного середовища набуває дедалі більшого поширення завдяки можливості керованого контролю мікроклімату, подовження періоду плодоношення та підвищення стабільності врожаю [1]. Одним із ключових технологічних етапів такого виробництва є своєчасне визначення стадії зрілості плодів, оскільки саме від цього залежить момент збору, товарна якість продукції, рівень післязбиральних втрат і раціональність планування агротехнічних операцій [2]. У традиційному підході оцінювання зрілості виконується оператором візуально, що робить процес трудомістким, суб'єктивним і залежним від досвіду людини, умов освітлення та щільності розміщення плодів у рослинному середовищі.

Розвиток методів комп'ютерного зору та глибокого навчання створює передумови для автоматизації визначення стадій зрілості плодів за цифровими зображеннями [3]. На відміну від підходів, що потребують спеціалізованих спектральних сенсорів або складного вимірювального обладнання, аналіз звичайних RGB-зображень є технологічно доступним і придатним для інтеграції в автономні тепличні комплекси. Нейромережеві детектори, зокрема моделі сімейства YOLO, дають змогу одночасно локалізувати плоди на зображенні та відносити їх до відповідних класів зрілості, що відкриває можливість формування оперативної аналітичної інформації для прийняття рішення щодо збору врожаю.

Водночас практичне застосування таких методів у реальних тепличних умовах ускладнюється низкою факторів, серед яких найбільш суттєвими є малий видимий розмір частини плодів, їх часткове перекриття листям або сусідніми ягодами, нерівномірне освітлення та близькість візуальних ознак між суміжними стадіями зрілості. У таких умовах критичного значення набуває не лише правильність класифікації вже знайдених об'єктів, а передусім повнота їх виявлення, оскільки пропущені плоди не потрапляють до подальшого аналізу і можуть спотворювати оцінку фактичного стану врожаю. Особливо це важливо для тепличного моніторингу, де система має не просто розпізнати окремі добре видимі плоди, а сформувати достатньо повну картину розподілу стиглих, напівстиглих і нестиглих ягід у кадрі.

Отже, актуальною науково-прикладною задачею є розроблення методу нейромережевої ідентифікації стадій зрілості плодів полуниці за RGB-зображеннями, орієнтованого на підвищення повноти виявлення плодів у складних умовах тепличного середовища. Розв'язання цієї задачі має значення для підвищення об'єктивності агротехнічного моніторингу, зменшення залежності від ручного візуального контролю та створення програмних засобів підтримки прийняття рішень в автономних тепличних комплексах.

**Об'єкт дослідження** – процес нейромережевого виявлення та ідентифікації стадій зрілості плодів полуниці за RGB-зображеннями.

**Предмет дослідження** – методи та засоби глибокого навчання для ідентифікації стадій зрілості плодів полуниці за RGB-зображеннями.

**Мета кваліфікаційної роботи бакалавра** полягає в підвищенні повноти визначення стадій зрілості плодів полуниці за RGB-зображеннями в умовах тепличного середовища шляхом розроблення методу нейромережевої ідентифікації стадій зрілості плодів полуниці за зображеннями на основі донавченої YOLO-моделі, що забезпечує автоматичну локалізацію плодів, визначення їхньої стадії зрілості та формування аналітичної інформації для прийняття рішення щодо збору врожаю.

**Завдання кваліфікаційної роботи бакалавра:** провести огляд та аналіз сучасних інформаційних моделей, методів комп'ютерного зору та моделей глибокого навчання для задач виявлення плодів і визначення їхніх стадій зрілості за RGB-зображеннями; формалізувати задачу нейромережевого виявлення та ідентифікації стадій зрілості плодів полуниці як задачу багатокласової детекції об'єктів у RGB-зображеннях тепличного середовища; розробити метод нейромережевого виявлення та класифікації плодів полуниці на основі донавченої YOLO-моделі, орієнтований на підвищення повноти ідентифікації стадій зрілості; реалізувати програмний засіб для опрацювання RGB-зображень, навчання моделі, виконання інференсу, візуалізації результатів і формування аналітичної інформації для прийняття рішення щодо збору врожаю; провести експериментальне дослідження розробленого методу з оцінюванням якості виявлення та ідентифікації стадій зрілості плодів полуниці.

## **Розділ 1 Характеристика предметної області: аналіз моделей, методів та реалізацій**

### **1.1 Аналіз інформаційних моделей**

Предметна область автоматизованого визначення стадій зрілості плодів полуниці охоплює отримання, опрацювання та інтерпретацію візуальної інформації про стан плодів у тепличному середовищі [2]. У цій задачі RGB-зображення є основним джерелом даних, з якого потрібно визначити наявність плодів, їх розміщення в кадрі та належність до певної стадії зрілості [3]. Такий підхід є актуальним для сучасного виробництва полуниці, оскільки своєчасне визначення моменту збору впливає на товарну якість продукції, рівень післязбиральних втрат і планування агротехнічних операцій [1].

Інформаційна модель цієї задачі описує перехід від неструктурованого цифрового зображення до впорядкованого набору відомостей, придатних для подальшого аналізу та прийняття рішення щодо збору врожаю. Вхідним елементом моделі є зображення тепличної сцени, на якому можуть бути представлені плоди полуниці, листя, стебла, субстрат, конструкції теплиці, тіні та інші фонові об'єкти [4]. Основна складність полягає в тому, що корисна інформація про плоди є лише частиною загального візуального змісту кадру, тому система має відокремити її від складного аграрного фону.

На відміну від лабораторних методів контролю, які можуть потребувати спеціалізованих сенсорів або додаткових вимірювальних засобів, використання RGB-зображень є більш доступним для практичного впровадження. Камера може бути встановлена стаціонарно в теплиці або використовуватися у складі мобільної платформи, що періодично фіксує стан рослин [5]. Це робить інформаційну модель на основі зображень придатною для автономних або напівавтономних тепличних комплексів.

Традиційне визначення зрілості полуниці здебільшого виконується шляхом візуального огляду, однак такий підхід залежить від досвіду працівника, умов освітлення, втоми, суб'єктивного сприйняття кольору та щільності

розміщення плодів [6]. У дослідженнях зазначається, що ручна оцінка зрілості та ручне збирання залишаються трудомісткими процесами і можуть призводити до неоднорідної післязбиральної якості продукції [7]. Тому виникає потреба у формалізованій інформаційній моделі, яка переводить суб'єктивне оцінювання в об'єктивний цифровий опис стану плодів.

У межах такої моделі кожен плід доцільно розглядати як окремий інформаційний об'єкт, для якого визначаються місце розташування в кадрі, візуальні межі, стадія зрілості та рівень достовірності результату [8]. Такий опис дає змогу сформувати структуровану картину стану врожаю, зокрема оцінити кількість стиглих, напівстиглих і нестиглих плодів та зробити висновок щодо доцільності збору [9].

Для задачі визначення зрілості полуниці доцільно виділяти три основні інформаційні стани плода: нестиглий, напівстиглий і стиглий [10]. Такий поділ відповідає практичній логіці тепличного вирощування: стиглі плоди потребують збору, нестигли залишаються для подальшого дозрівання, а напівстигли потребують повторного контролю [11]. Водночас межі між цими станами не завжди є чіткими, оскільки дозрівання відбувається поступово, а зовнішні ознаки можуть змінюватися нерівномірно [12]. Особливо складною є напівстигла стадія, яка поєднує ознаки сусідніх класів.

Візуальна інформація про стиглість формується переважно за рахунок кольору, видимої площі плода, текстури поверхні та співвідношення забарвлених і незабарвлених ділянок [13]. У реальному тепличному середовищі ці ознаки можуть спотворюватися через нерівномірне освітлення, затінення листям, відблиски, різну відстань до камери та зміну кута огляду [14]. Додатковими ускладненнями є часткове перекриття плодів листям або іншими ягодами, щільне розміщення рослин і малий видимий розмір окремих об'єктів. У дослідженнях із розпізнавання зрілості полуниці підкреслюється, що складне середовище вирощування, зміни освітлення та затінення через скупчення плодів істотно ускладнюють автоматизоване визначення їхнього стану [15].

З позиції інформаційного моделювання задача не може бути зведена лише до загальної оцінки всього зображення. Для практичного застосування потрібно знати, які саме плоди наявні в кадрі, де вони розташовані та до якої стадії зрілості належать [16]. Тому результатом опрацювання має бути не одна загальна мітка, а структурований набір локалізованих плодів із відповідними класами зрілості. Саме такий формат дає змогу перейти від простого розпізнавання до агротехнічної аналітики: підрахунку плодів за класами, визначення частки стиглих ягід, виявлення проблемних зон і формування рекомендації щодо збору [17].

Узагальнена інформаційна модель процесу передбачає кілька рівнів: формування цифрового зображення тепличної сцени, підготовку даних до опрацювання, виділення об'єктів інтересу та визначення їхніх стадій зрілості, а також перетворення результатів у аналітичну інформацію для підтримки прийняття рішення щодо збору врожаю. Така логіка відповідає загальній тенденції розвитку систем автоматизації аграрних процесів, у яких цифрові дані використовуються для підвищення об'єктивності моніторингу та зменшення залежності від ручної праці [18].

Особливе значення для цієї моделі має повнота виявлення плодів. Якщо частина ягід не буде виявлена, подальша аналітика стане неповною, навіть за правильної класифікації знайдених плодів. Для тепличного моніторингу це має практичні наслідки: пропущені стиглі плоди можуть бути не враховані під час планування збору, а пропущені напівстигли або нестигли плоди можуть спотворити уявлення про фактичний стан грядки [19].

Сучасні огляди систем розпізнавання плодів в аграрному середовищі вказують, що типовими проблемами залишаються нестача якісних наборів даних, складність виявлення малих об'єктів, часткові перекриття, щільне розміщення плодів, різні масштаби об'єктів і необхідність практичного використання систем у реальних умовах [20]. Ці проблеми характерні і для тепличного вирощування полуниці, де плоди можуть бути розміщені на різній

відстані від камери, частково приховані листям або мати схоже забарвлення з елементами фону.

Отже, автоматизоване визначення стадій зрілості плодів полуниці за RGB-зображеннями доцільно розглядати як процес перетворення зображення тепличної сцени у структурований опис стану врожаю. Такий опис має містити відомості про розташування плодів, їхню стадію зрілості та узагальнені показники, потрібні для прийняття рішення щодо збору. Основними обмеженнями предметної області залишаються змінне освітлення, складний фон, часткові перекриття, малий видимий розмір окремих плодів і нечіткість меж між суміжними стадіями зрілості.

## **1.2 Огляд моделей глибокого навчання для задач детекції об'єктів**

Задача детекції об'єктів є базовою для комп'ютерного зору, оскільки поєднує локалізацію об'єкта на зображенні та визначення його класу [21]. На відміну від класифікації, де результатом є одна мітка для всього кадру, детекція передбачає виявлення всіх цільових об'єктів у сцені та формування для кожного з них окремого просторового й семантичного опису [22]. Результатом роботи детектора є координати обмежувальних рамок і ймовірність належності об'єкта до певного класу. Для ідентифікації стадій зрілості полуниці це принципово важливо, оскільки на одному зображенні можуть одночасно бути плоди різних стадій дозрівання, які потребують незалежного аналізу.

Сучасні моделі детекції об'єктів розвивалися від складних багатостадійних схем до компактних архітектур, здатних працювати в режимі, близькому до реального часу. У сучасному огляді розвитку детекції об'єктів зазначається, що основний прогрес у цій галузі пов'язаний із переходом до глибокого навчання, удосконаленням згорткових архітектур, появою багатомасштабного виділення ознак та оптимізацією моделей для швидкого інференсу [24]. Значний внесок у підвищення ефективності сучасних детекторів також зробили механізми автоматичного виділення інформативних ознак,

використання залишкових з'єднань, методів агрегації ознак різних рівнів та вдосконалення функцій втрат. Завдяки цим підходам сучасні нейронні мережі демонструють високу точність навіть у складних умовах зйомки та за наявності великої кількості об'єктів у кадрі.

Для прикладних задач аграрного моніторингу це особливо важливо, оскільки модель має обробляти складні сцени з неоднорідним фоном, змінним освітленням, перекриттями та об'єктами різного видимого розміру. Додатковими факторами, що ускладнюють процес детекції плодів полуниці, є часткове закриття ягід листям, варіації кольору залежно від сорту та умов вирощування, а також наявність тіней і відблисків на поверхні плодів. У таких умовах ефективність системи значною мірою залежить від здатності моделі формувати стійкі та узагальнені ознаки, які дозволяють коректно розпізнавати об'єкти незалежно від зовнішніх змін. Саме тому сучасні архітектури детекції об'єктів широко використовуються в системах точного землеробства, автоматизованого збору врожаю та моніторингу стану сільськогосподарських культур. За загальною логікою роботи детектори об'єктів поділяють на дві основні групи: двостадійні та однастадійні. Двостадійні детектори спочатку формують набір потенційних областей, у яких можуть міститися об'єкти, а потім уточнюють ці області та класифікують знайдені об'єкти. До цього напряму належать архітектури родини R-CNN, які історично забезпечили високий рівень точності локалізації, однак мають підвищену обчислювальну складність. У сучасних оглядах такі моделі розглядаються як важливий етап розвитку виявлення об'єктів, але для задач оперативного моніторингу їхня практична доцільність є обмеженою через нижчу швидкість порівняно з однастадійними підходами [24].

Однастадійні детектори виконують локалізацію та класифікацію об'єктів за один прохід моделі. Завдяки цьому вони краще відповідають вимогам систем реального часу, де важливо отримувати результат без значної затримки [25]. До цієї групи належать SSD, RetinaNet, EfficientDet та моделі сімейства YOLO. Їхньою спільною перевагою є швидкість опрацювання зображення, а основним викликом залишається збереження достатньої точності для дрібних, частково

перекритих або візуально слабо виражених об'єктів [26]. Саме такі умови характерні для тепличних зображень полуниці, де окремі плоди можуть бути віддаленими від камери, частково закритими листям або представленими невеликою кількістю пікселів.

Особливе місце серед одностадійних детекторів займає сімейство YOLO, основна ідея якого полягає в цілісному аналізі зображення та одночасному передбаченні положення й класу об'єктів. У сучасному огляді архітектур YOLO показано, що розвиток цього сімейства спрямований на досягнення балансу між точністю, швидкістю та придатністю до розгортання в прикладних системах [27]. Для визначення стадій зрілості полуниці такий баланс є критичним, оскільки система має бути не лише точною, а й придатною для практичного тепличного моніторингу. Новіші версії YOLO використовують удосконалені блоки виділення ознак, багаторівневе об'єднання інформації та оптимізовані механізми передбачення обмежувальних рамок, що покращує роботу з різними масштабами об'єктів і складними сценами. Водночас одностадійні детектори залишаються чутливими до малих об'єктів, які мають обмежену кількість візуальних ознак і можуть губитися на складному фоні. У сучасному огляді методів виявлення дрібних об'єктів зазначено, що ключовими напрямками підвищення якості є покращення виділення ознак, використання контексту та адаптація архітектури до малих цілей [28].

Для аграрних задач проблема малих об'єктів має не теоретичний, а безпосередньо прикладний характер. Плоди в реальній сцені можуть бути розміщені на різній відстані від камери, мати різний ступінь освітлення та частково перекриватися листям. У дослідженні, присвяченому виявленню зрілості полуниці за допомогою YOLOv8 і LW-Swin Transformer, підкреслюється, що складне середовище вирощування, інтерференція освітлення та затінення через скупчення плодів істотно ускладнюють автоматичне розпізнавання [15]. Це підтверджує доцільність використання моделей, здатних поєднувати швидке виявлення об'єктів із достатньо стійким виділенням візуальних ознак у складних умовах.

Узагальнене порівняння основних типів моделей детекції об'єктів наведено в таблиці 1.1.

Таблиця 1.1 – Порівняльний аналіз моделей глибокого навчання для задач детекції об'єктів

Тип моделей	Приклади	Характеристика та доцільність для задачі
Двостадійні детектори [24]	R-CNN, Fast R-CNN, Faster R-CNN	Висока якість локалізації, але мають значну обчислювальну складність і нижчу швидкодію, тому менш придатні для оперативного тепличного моніторингу.
Одностадійні детектори [24]	SSD, RetinaNet, EfficientDet	Виконують локалізацію та класифікацію за один прохід моделі, тому краще відповідають задачам, де потрібен баланс між швидкістю та якістю виявлення плодів.
Моделі сімейства YOLO [27]	YOLOv7, YOLOv8, YOLOv11	Орієнтовані на швидку детекцію в режимі, близькому до реального часу, та дають змогу одночасно знаходити плоди і визначати їхній клас.
YOLO-моделі для визначення зрілості полуниці [23]	YOLOv7 + AR	Підтверджують практичну придатність YOLO-підходу для розпізнавання стадій зрілості полуниці в тепличному середовищі.
Модифіковані YOLO-моделі для полуниці [15]	LS-YOLOv8s	Адаптовані до складного аграрного фону, змінного освітлення та затінення плодів, тому є релевантними для задачі тепличного розпізнавання.
Сучасні YOLOv11-модифікації для полуниці [30]	YOLOv11-GSF	Орієнтовані на роботу в реальному часі та покращення розпізнавання плодів у складних умовах вирощування.

У задачах визначення зрілості полуниці сучасні дослідження переважно орієнтуються на модифіковані або донавчені YOLO-моделі. У роботі з використанням YOLOv7 та доповненої реальності показано можливість реального часу для виявлення стадій зрілості полуниці в тепличних умовах [23]. Інші дослідження пропонують удосконалення YOLOv8 за рахунок механізмів уваги або трансформерних компонентів, що дає змогу підвищити якість виділення ознак і працювати зі складним фоном [29]. Також для цієї задачі застосовуються оптимізовані моделі на основі YOLOv11, що підтверджує актуальність саме цього напрямку [30].

Як видно з порівняння, для задач, що потребують роботи в режимі, близькому до реального часу, доцільним є вибір одностадійного детектора сімейства YOLO. Водночас спільним вузьким місцем одностадійних детекторів залишається саме розпізнавання дрібних об'єктів, що зумовлює потребу в додаткових механізмах підвищення точності для таких цілей.

### **1.3 Огляд теоретичних підходів до розв'язання задачі визначення зрілості**

Задача визначення стадії зрілості плодів полуниці належить до прикладних задач аграрного комп'ютерного зору, у яких необхідно інтерпретувати зовнішні візуальні ознаки плода та віднести його до певного стану готовності до збору. Теоретично ця задача може розглядатися як задача класифікації, якщо аналізується окремий плід або фрагмент зображення, і як задача детекції з класифікацією, якщо потрібно одночасно знайти всі плоди в кадрі та визначити стадію зрілості кожного з них. Для тепличного середовища більш придатною є друга постановка, оскільки в одному зображенні зазвичай міститься кілька плодів різних стадій зрілості, розташованих на різній відстані від камери та частково перекритих листям.

Найпростішим теоретичним підходом до визначення зрілості є оцінювання зовнішніх колірних ознак. Дозрівання полуниці супроводжується поступовою зміною забарвлення плода, тому колір є одним із ключових інформаційних показників. На цій основі можуть виділятися такі класи, як нестиглий, напівстиглий і стиглий плід. Однак використання лише колірних характеристик має суттєві обмеження, оскільки в реальних умовах теплиці колір на зображенні залежить не тільки від фізичного стану плода, а й від освітлення, тіней, кута зйомки та фону. У дослідженнях із визначення зрілості полуниці підкреслюється, що ручна оцінка зрілості значною мірою залежить від суб'єктивного сприйняття людини та може призводити до неоднорідної післязбиральної якості продукції [23].

Іншим підходом є аналіз попередньо виділених зображень або фрагментів, що містять один плід. У цьому разі задача зводиться до класифікації стадії зрілості за візуальними ознаками конкретного об'єкта, що спрощує її постановку. Проте для реального тепличного моніторингу такий підхід є обмеженим, оскільки не дозволяє визначити розташування плодів, їх кількість у кадрі та готовність до збору. Тому практично доцільнішим є подання задачі як багатокласової детекції об'єктів, за якої кожен плід розглядається як окремий об'єкт із визначеним положенням у кадрі та класом зрілості. Це дає змогу сформулювати не лише оцінку стану окремого плода, а й узагальнену картину врожаю на певній ділянці теплиці [23]. Практична реалізація такого підходу ускладнюється щільним розміщенням плодів, частковими перекриттями, різним видимим розміром об'єктів і нерівномірним освітленням. У роботі, присвяченій LS-YOLOv8s для визначення зрілості полуниці, зазначено, що складне середовище вирощування, зміна інтенсивності світла та затінення через скупчення плодів ускладнюють точне виявлення й класифікацію стиглості [15]. Особливо проблемними є дрібні та частково перекриті плоди, які містять мало інформативних пікселів і можуть спричиняти пропуски або помилки класифікації. Огляд досліджень із виявлення фруктів для автоматизованого збору врожаю також підтверджує, що типовими викликами залишаються малі об'єкти, оклюзії, щільні сцени, різні масштаби та потреба в легких моделях для практичного розгортання [20].

У новіших дослідженнях для визначення зрілості полуниці пропонуються оптимізовані підходи, придатні для роботи в реальному часі та складних умов вирощування. Зокрема, YOLOv11-GSF розглядається як модель для оперативного визначення зрілості полуниці, спрямована на підвищення якості розпізнавання та зниження обчислювальних витрат [30]. Це підтверджує перехід від простого аналізу кольору до комплексного підходу, що поєднує локалізацію плодів, класифікацію їхнього стану та формування структурованої аналітики.

Отже, для визначення стадій зрілості плодів полуниці найбільш обґрунтованим є підхід багатокласової детекції за RGB-зображеннями, який дає

змогу одночасно локалізувати плоди, класифікувати їхню зрілість і сформувати основу для прийняття рішення щодо збору врожаю. Основними обмеженнями залишаються залежність від освітлення, складність розпізнавання напівстиглого класу, часткові перекриття та малий видимий розмір плодів.

#### **1.4 Мета та завдання роботи**

Метою кваліфікаційної роботи бакалавра є підвищення повноти визначення стадій зрілості плодів полуниці за RGB-зображеннями в умовах тепличного середовища шляхом розроблення методу нейромережевої ідентифікації стадій зрілості плодів полуниці за зображеннями на основі донавченої YOLO-моделі, що забезпечує автоматичну локалізацію плодів, визначення їхньої стадії зрілості та формування аналітичної інформації для прийняття рішення щодо збору врожаю.

Для досягнення поставленої мети потрібно виконати такі завдання:

- провести огляд та аналіз сучасних інформаційних моделей, методів комп'ютерного зору та моделей глибокого навчання для задач виявлення плодів і визначення їхніх стадій зрілості за RGB-зображеннями;
- формалізувати задачу нейромережевого виявлення та ідентифікації стадій зрілості плодів полуниці як задачу багатокласової детекції об'єктів у RGB-зображеннях тепличного середовища;
- розробити метод нейромережевого виявлення та класифікації плодів полуниці на основі донавченої YOLO-моделі, орієнтований на підвищення повноти ідентифікації стадій зрілості;
- реалізувати програмний засіб для опрацювання RGB-зображень, навчання моделі, виконання інференсу, візуалізації результатів і формування аналітичної інформації для прийняття рішення щодо збору врожаю;
- провести експериментальне дослідження розробленого методу з оцінюванням якості виявлення та ідентифікації стадій зрілості плодів полуниці.

## Розділ 2 Метод нейромережевої ідентифікації стадій зрілості плодів полуниці

У цьому розділі наведено математичну та алгоритмічну формалізацію задачі нейромережевого виявлення та ідентифікації стадій зрілості плодів полуниці за RGB-зображеннями, обґрунтовано вибір детектора об'єктів, описано структуру розроблюваного методу, підготовку набору даних і метрики оцінювання. Особливу увагу приділено підходам до підвищення повноти виявлення плодів у складних умовах тепличного середовища, зокрема для дрібних, віддалених і частково перекритих об'єктів. Також сформовано сценарій експериментального дослідження для оцінювання якості роботи методу.

### 2.1 Формалізація задачі детекції та класифікації стадій зрілості

Розроблюваний метод реалізує перетворення вхідного зображення тепличної сцени у структуровану множину виявлених плодів із визначеною стадією зрілості кожного з них. Формально вхідним даним відповідає кольорове зображення  $I$  розмірності  $H \times W \times 3$  (висота, ширина та три колірні канали). Метою методу є побудова алгоритмічного оператора  $\Phi$ , який ставить у відповідність зображенню множину виявлених об'єктів  $O$ .

$$\Phi: I \rightarrow O. \quad (2.1)$$

Кожен виявлений об'єкт описується вектором просторово-семантичного стану, що містить координати геометричного центру обмежувальної рамки, її габарити, ідентифікатор класу та рівень довіри моделі:

$$d = (x, y, w, h, c, p), \quad (2.2)$$

де  $(x, y)$  – координати центру рамки;  $(w, h)$  – її ширина та висота;  $c$  – клас зрілості (нестигла, напівстигла, стигла);  $p$  – рівень довіри (Confidence Score). Сукупність усіх виявлених на зображенні об'єктів формує множину детекцій:

$$O = \{d_1, d_2, \dots, d_M\}. \quad (2.3)$$

Оператор  $\Phi$  реалізується нейромережею з параметрами (вагами)  $\theta$ , які налаштовуються шляхом мінімізації функціонала втрат  $L$  на навчальній вибірці з еталонними мітками  $Y$ :

$$\theta^* = \arg \min_{\theta} \sum L(\Phi_{\theta}(I), Y). \quad (2.4)$$

Базовою геометричною мірою якості локалізації та основою як функції втрат, так і метрик оцінювання, є коефіцієнт перекриття площ (Intersection over Union, IoU), який формалізує відношення площі перетину передбаченої рамки  $A$  та еталонної рамки  $B$  до площі їх об'єднання [31]:

$$\text{IoU} = |A \cap B| / |A \cup B|. \quad (2.5)$$

На етапі формування остаточного набору детекцій застосовується алгоритм придушення немаксимумів (Non-Maximum Suppression, NMS), який за метрикою IoU усуває дублюючі рамки навколо одного об'єкта, залишаючи лише рамку з найвищим рівнем довіри. Оскільки на загальних планах теплиці плоди малого видимого розміру є найскладнішими для детекції, у п. 2.3 постановку задачі доповнено механізмом фрагментованого інференсу, спрямованим саме на підвищення точності для таких об'єктів.

Узагальнено розроблюваний метод можна подати як послідовність перетворень, у межах якої вхідне RGB-зображення тепличної сцени переходить у структурований набір детекцій плодів із визначеними просторовими координатами, класом зрілості та рівнем довіри моделі. Узагальнену схему методу нейромережевої ідентифікації стадій зрілості плодів полуниці наведено на рисунку 2.1.



Рисунок 2.1 – Схема методу нейромережевої ідентифікації стадій зрілості плодів полуниці

Така схема відображає логіку роботи методу: від подання зображення ( $I$ ), його опрацювання оператором ( $\Phi, \theta$ ), формування множини виявлених об'єктів ( $O$ ), опису кожного об'єкта вектором ( $d$ ), до геометричної перевірки локалізації за IoU та усунення дублюючих рамок за допомогою NMS.

## 2.2 Детекція об'єктів за допомогою нейромережі YOLO

Як ядро підсистеми детекції обрано одностадійну нейромережу сімейства YOLO, що забезпечує оптимальний компроміс між точністю та швидкістю і реалізує без'якірний (anchor-free) підхід, придатний для розпізнавання плодів зі змінною геометрією [30]. Архітектура мережі складається з трьох функціональних блоків: магістралі ознак (Backbone), блоку агрегації (Neck) та модуля передбачення (Head) [24].

Магістраль виконує роль багаторівневого екстрактора ознак, поступово зменшуючи просторову роздільність і нарощуючи семантичну глибину. Блок агрегації будується за принципом пірамідального злиття ознак різних масштабів, що розвиває ідею мережі Feature Pyramid Network та запобігає втраті дрібних об'єктів [32]. Модуль передбачення є роздільним (decoupled): одна гілка відповідає за класифікацію, інша – за регресію координат рамок [5]. На мікрорівні архітектура використовує оптимізовані згорткові блоки (зокрема CBS, C2f та SPPF), які зменшують обчислювальну складність і розширюють рецептивне поле мережі.

Навчання моделі полягає в ітеративній мінімізації багатокomпонентної функції втрат, що поєднує втрати локалізації рамок, класифікації та розподілу координат:

$$L = \lambda_{box}L_{box} + \lambda_{cls}L_{cls} + \lambda_{dfl}L_{dfl}, \quad (2.6)$$

де  $\lambda$  – вагові коефіцієнти, що балансують внесок кожної складової. Втрати локалізації обчислюються за метрикою Complete IoU (CIoU), яка, окрім площі перетину, враховує відстань між центрами рамок та розбіжність співвідношення їх сторін [19]:

$$L_{Clou} = 1 - \text{IoU} + \rho^2(b, b^{gt}) / c^2 + \alpha v, \quad (2.7)$$

де  $\rho(b, b^{gt})$  – евклідова відстань між центрами передбаченої та еталонної рамок;  $c$  – діагональ найменшого прямокутника, що охоплює обидві рамки;  $v$  – міра розбіжності співвідношення сторін;  $\alpha$  – адаптивний ваговий коефіцієнт. Зокрема:

$$v = (4/\pi^2)(\arctan(w_{gt}/h_{gt}) - \arctan(w/h))^2, \quad (2.8)$$

а коефіцієнт компромісу визначається як  $\alpha = v / ((1 - \text{IoU}) + v)$ . Втрати класифікації обчислюються через бінарну перехресну ентропію (Binary Cross-Entropy), що застосовується до кожного класу за принципом «one-vs-all»:

$$L_{cls} = -[y \log(p) + (1 - y) \log(1 - p)], \quad (2.9)$$

де  $y$  – еталонна мітка класу,  $p$  – передбачена ймовірність належності до нього. Складова  $L_{dfl}$  (Distribution Focal Loss) моделює координати рамки як неперервний розподіл імовірностей, що підвищує точність визначення меж об'єктів зі змазаними контурами; ця складова належить до родини фокальних функцій втрат, які знижують вплив дисбалансу класів та домінування фонових прикладів під час навчання [33]. Оптимізація ваг здійснюється адаптивними методами градієнтного спуску зі зворотним поширенням помилки.

Узагальнена архітектура детектора YOLO, використаного в межах розроблюваного методу, може бути подана як послідовність трьох основних функціональних частин: Backbone, Neck та Head. На вхід моделі подається RGB-зображення фіксованого розміру, після чого магістральна частина мережі виділяє ознаки різного рівня абстракції. Далі блок агрегації поєднує ознаки різних масштабів, що є важливим для виявлення плодів різного видимого розміру. Завершальний модуль передбачення формує вихідні детекції, які містять координати рамок, клас зрілості та рівень довіри моделі. Узагальнену схему архітектури YOLO для задачі ідентифікації стадій зрілості плодів полуниці наведено на рисунку 2.2.

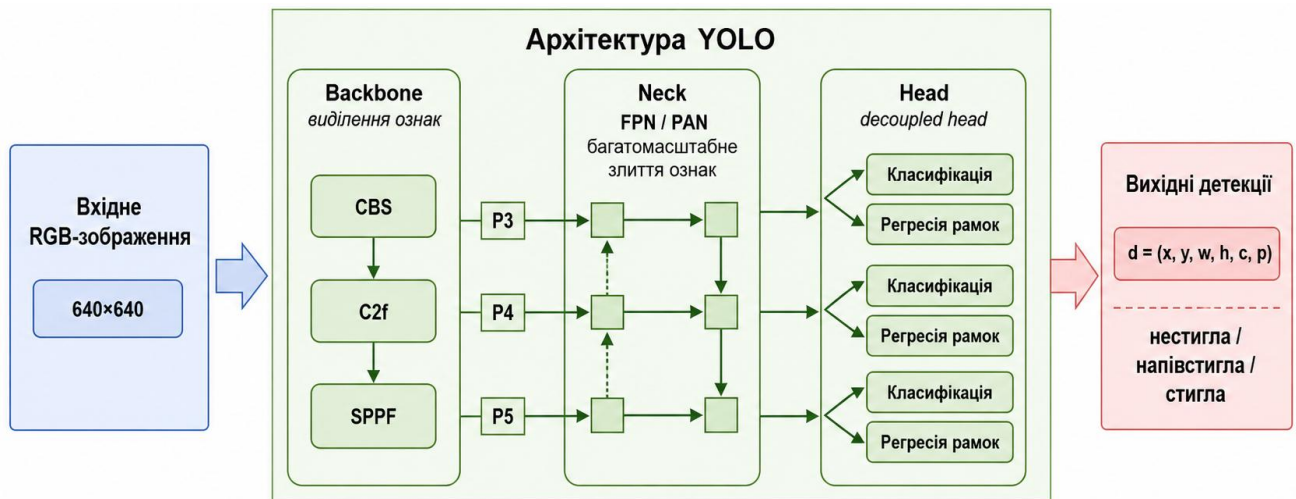


Рисунок 2.2 – Архітектура YOLO-детектора для ідентифікації стадій зрілості плодів полуниці

Архітектура YOLO забезпечує перехід від вхідного RGB-зображення до множини вихідних детекцій у межах єдиного нейромережевого конвеєра. Використання багатомасштабних ознак дозволяє враховувати плоди різного розміру, а розділення гілок класифікації та регресії рамок дає змогу одночасно визначати просторове положення плода і його стадію зрілості. Така структура є придатною для задачі тепличного моніторингу, оскільки поєднує локалізацію об'єктів, класифікацію їхнього стану та формування вихідного вектора детекції ( $d = (x, y, w, h, c, p)$ ).

### 2.3 Фрагментований інференс для детекції дрібних плодів

Ключовою науково-технічною складовою розроблюваного методу є інтеграція фрагментованого інференсу (Slicing Aided Hyper Inference, SAHI), спрямованого на підвищення точності розпізнавання дрібних, віддалених та частково перекритих плодів. Проблема полягає в тому, що під час приведення зображення високої роздільності до фіксованого входу мережі (наприклад,  $640 \times 640$ ) дрібні плоди представлені малою кількістю пікселів і втрачають інформативні ознаки [34].

Сутність методу полягає в нарізці вхідного зображення на множину перекривних фрагментів фіксованого розміру з подальшим незалежним аналізом

кожного фрагмента та злиттям результатів. Формально множина фрагментів задається як:

$$P = \{P_{i,j}\}, \text{ розмір } s \times s, \text{ перекриття } r \quad (2.10)$$

де  $s$  – розмір фрагмента (типово  $640 \times 640$ ), а  $r$  – коефіцієнт перекриття сусідніх фрагментів (близько 0,2), що запобігає втраті об'єктів на межах нарізки. До кожного фрагмента застосовується детектор:

$$D_{i,j} = \Phi_{\theta}(P_{i,j}). \quad (2.11)$$

Координати отриманих рамок переводяться у систему координат вихідного зображення. Додатково може виконуватися інференс на повному кадрі для надійного виявлення великих плодів. Усі детекції об'єднуються та обробляються глобальним придушенням немаксимумів:

$$D = \text{NMS}(\text{shift}(D_{i,j}) \cup \Phi_{\theta}(I)). \quad (2.12)$$

Завдяки нарізці дрібний плід займає відносно більшу частку площі фрагмента, що підвищує його помітність для мережі та точність локалізації. Послідовність перетворень формалізовано у вигляді Алгоритму 2.1.

### Алгоритм 2.1 – Фрагментований інференс для детекції стадій зрілості

**Вхід:** зображення  $I$ ; навчена модель  $\Phi_{\theta}$ ; розмір фрагмента  $s$ ; коефіцієнт перекриття  $r$ ; пороги NMS.

**Вихід:** множина детекцій  $D$  з координатами рамок та класами зрілості.

1. Розбити  $I$  на перекривні фрагменти  $P = \{P(i,j)\}$  розміром  $s \times s$  з перекриттям  $r$ .
2. Для кожного фрагмента  $P(i,j)$ : обчислити  $D(i,j) = \Phi_{\theta}(P(i,j))$  та перевести координати рамок у систему вихідного зображення.
3. (Опційно) виконати інференс на повному кадрі  $\Phi_{\theta}(I)$  для надійного виявлення великих плодів.
4. Об'єднати всі детекції та застосувати глобальне придушення немаксимумів (NMS) за метрикою IoU.
5. Повернути  $D$ .

Метод є універсальним і застосовується поверх обраного детектора без зміни його архітектури; за потреби якість може додатково підвищуватися донавчанням на нарізаних зображеннях.

Узагальнено фрагментований інференс у межах розроблюваного методу можна подати як послідовність етапів, у якій вхідне RGB-зображення високої роздільності спочатку нарізається на множину перекривних фрагментів, далі кожен фрагмент окремо опрацьовується детектором, після чого отримані результати переносяться у систему координат вихідного зображення та об'єднуються в єдину множину кандидатних детекцій. На завершальному етапі виконується глобальна постобробка, що усуває дублікати рамок у зонах перекриття та формує остаточний набір виявлених плодів із визначеними класами зрілості. Схему фрагментованого інференсу для детекції дрібних плодів наведено на рисунку 2.3.

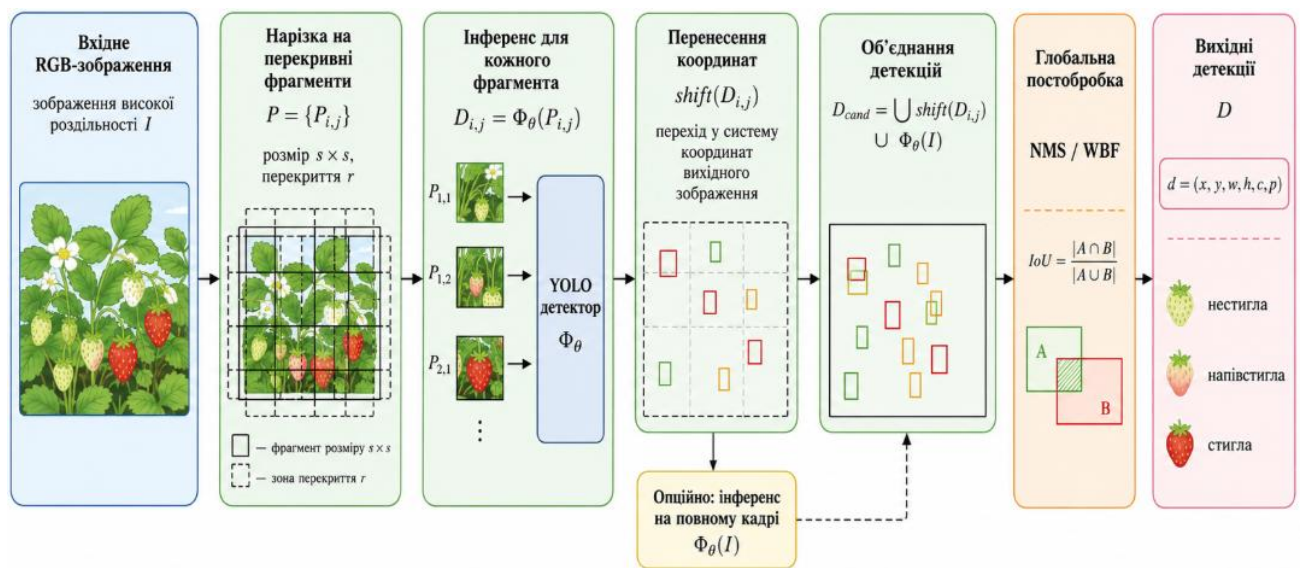


Рисунок 2.3 – Схема інференсу для детекції дрібних плодів

Застосування фрагментованого інференсу дає змогу підвищити помітність дрібних, віддалених і частково перекритих плодів за рахунок їх аналізу в межах окремих локальних фрагментів. Водночас нарізка зображення спричиняє появу дублюючих детекцій у зонах перекриття, тому обов'язковою складовою методу є етап глобальної постобробки на основі IoU та NMS або WBF. У підсумку формується остаточна множина детекцій, придатна для

подальшого визначення стадій зрілості плодів та оцінювання повноти їх виявлення.

## 2.4 Опис набору даних та підготовка

Для навчання та оцінювання моделі використано публічний спеціалізований набір даних детекції зрілості полуниці [35]. Після підготовки та приведення розмітки до формату детекції набір містить 566 RGB-зображень і 1734 bbox-анотації плодів полуниці, розподілені між трьома класами зрілості: стиглий, напівстиглий та нестиглий. Зображення зібрано у двох тепличних середовищах за змінних умов освітлення (пряме сонце, часткове затінення, розсіяне освітлення). Набір характеризується природним дисбалансом класів та наявністю дрібних і частково перекритих плодів, що відтворює реальні умови експлуатації. На рисунку 2.4 наведено розподіл зразків по класам.

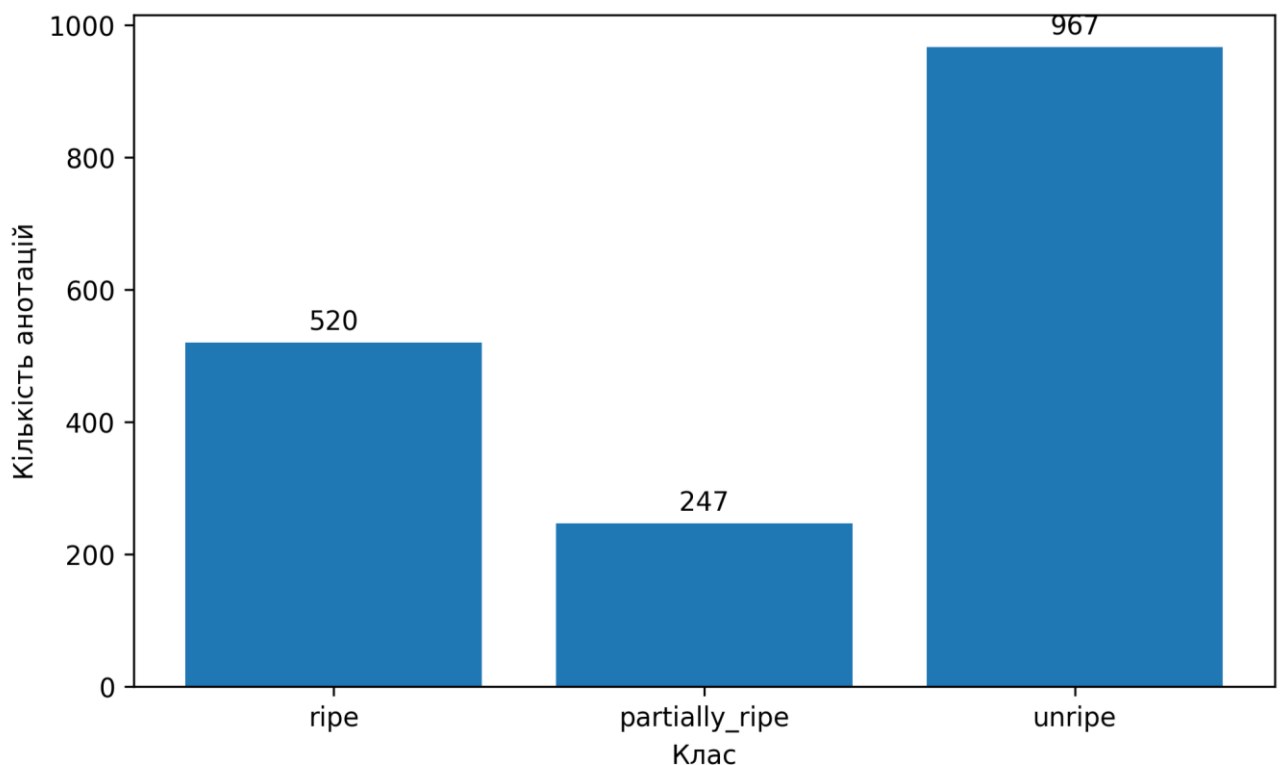


Рисунок 2.4 – Розподіл зразків по класам

Для коректного оцінювання узагальнюючої здатності моделі набір поділяється на навчальну, валідаційну та тестову вибірки. Зображення приводяться до фіксованої тензорної розмірності входу мережі ( $640 \times 640$ )

методом доповнення країв (letterboxing), що зберігає геометричні пропорції плодів та запобігає спотворенню силуетів; значення пікселів нормалізуються з діапазону  $[0, 255]$  у  $[0, 1]$  для стабілізації навчання. Загальна кількість bbox-анотацій після підготовки даних становить 1734, що відповідає сумарній кількості об'єктів у навчальній, валідаційній та тестовій вибірках.

Для підвищення стійкості моделі до варіативних умов зйомки застосовуються методи динамічної аугментації даних – мозаїчне поєднання зображень (Mosaic), зміна колірних характеристик у просторі HSV та випадкові горизонтальні відображення, що належать до стандартних прийомів навчання сучасних детекторів. Доцільність аугментації підтверджується дослідженнями, які демонструють її істотний вплив на точність детекції та стійкість моделей згорткових мереж [36].

## 2.5 Метрики оцінювання

Оцінювання якості розробленого методу базується на стандартизованому апараті метрик детекції об'єктів. Первинною геометричною мірою є коефіцієнт перекриття IoU (формула 2.5), за пороговим значенням якого детекції розподіляються на істинно позитивні (TP), хибно позитивні (FP) та хибно негативні (FN) і будується матриця помилок (Confusion Matrix). Оскільки у теплих сценах фонові пікселі кількісно домінують над цільовими об'єктами, метрика загальної точності (Accuracy) є нерепрезентативною; тому використовуються метрики, сфокусовані на цільових об'єктах [37].

Точність (Precision) відображає здатність моделі не генерувати хибні спрацьовування, а повнота (Recall) – здатність виявляти всі наявні плоди:

$$P = TP / (TP + FP) \quad (2.13)$$

$$R = TP / (TP + FN) \quad (2.14)$$

Для оцінки компромісу між ними застосовується гармонійне середнє F1:

$$F_1 = 2 PR / (P + R) \quad (2.15)$$

Головною інтегральною метрикою є середня усереднена точність (mean Average Precision, mAP). Для кожного класу обчислюється усереднена точність AP як площа під кривою залежності точності від повноти, після чого результати усереднюються за всіма N класами [38].

Для оцінювання застосовуються показники mAP@0.5 (за порогом IoU = 0,5) та жорсткіший mAP@0.5:0.95 (усереднення за діапазоном порогів). Окремо, для перевірки центральної гіпотези дослідження, передбачено аналіз точності в розрізі розміру об'єктів: показники AP та Recall обчислюються окремо для дрібних, середніх і великих плодів, що дозволяє ізолювати приріст, який дає фрагментований інференс саме на дрібних цілях.

## 2.6 Сценарій експериментального дослідження

Метою експериментального дослідження є об'єктивна оцінка точності ідентифікації стадій зрілості та перевірка ефективності інтеграції фрагментованого інференсу. Гіпотеза дослідження полягає в тому, що інтеграція методу SAHI у конвеєр детекції підвищує точність розпізнавання дрібних, віддалених і частково перекритих плодів порівняно з базовим детектором без неприйнятної зниження швидкодії для сценарію автономного тепличного комплексу.

Випробування плануються в ізолюваному апаратно-програмному середовищі з використанням графічного прискорювача з підтримкою CUDA [39]; програмна реалізація – мовою Python із застосуванням фреймворку глибокого навчання та бібліотек комп'ютерного зору. Поділ даних здійснюється за цілісними зображеннями (а не випадковими фрагментами) для запобігання витоку даних. Для статистичної достовірності оцінювання проводиться шляхом кількох незалежних запусків з фіксацією середніх значень та стандартного відхилення. Програма досліджень структурно поділена на три сценарії, зведені в таблиці 2.1.

**Таблиця 2.1 – Сценарії експериментального дослідження**

Сценарій	Зміст	Метрики
Базове порівняння	Зіставлення базового детектора (інференс на повному кадрі) та конфігурації з інтеграцією SANI	mAP@0.5, mAP@0.5:0.95, Precision, Recall, FPS
Абляційне дослідження	Аналіз точності в розрізі розміру об'єктів для підтвердження приросту саме на дрібних плодах	AP та Recall окремо для дрібних/середніх/великих об'єктів
Оцінка швидкодії	Вимірювання часу інференсу та частоти кадрів із SANI та без нього; аналіз компромісу «точність – швидкодія»	Час інференсу, FPS

Такий деталізований підхід дозволяє всебічно перевірити працездатність методу, сформувавши емпіричну доказову базу та об'єктивно підтвердити, що підвищення точності досягається саме за рахунок інтегрованого механізму фрагментованого інференсу для дрібних об'єктів.

## 2.7 Висновки до розділу 2

У другому розділі розроблено метод нейромережевої ідентифікації стадій зрілості плодів полуниці за RGB-зображеннями, який формалізує задачу як багатокласову детекцію об'єктів у тепличному середовищі. Запропонований підхід передбачає перетворення вхідного зображення у структуровану множину детекцій, де кожен виявлений плід описується координатами обмежувальної рамки, класом зрілості та рівнем довіри моделі. Така постановка дає змогу поєднати в одному методі локалізацію плодів і визначення їхньої стадії зрілості, що є важливим для подальшого формування агротехнічної аналітики.

Як базовий компонент методу обґрунтовано використання одностадійного детектора сімейства YOLO, який забезпечує раціональний компроміс між якістю виявлення об'єктів і швидкістю обробки зображень [40]. У межах методу враховано архітектурну логіку YOLO-детектора, що включає виділення ознак, багатомасштабне злиття та формування вихідних детекцій через розділені гілки класифікації й регресії рамок. Це дозволяє адаптувати нейромережевий конвеєр до задачі виявлення плодів різного видимого розміру та визначення їхньої належності до класів “нестигла”, “напівстигла” і “стигла”.

Особливістю запропонованого методу є орієнтація не лише на правильну класифікацію знайдених плодів, а й на підвищення повноти їх виявлення. Для цього в метод включено режим фрагментованого інференсу, за якого зображення високої роздільності нарізається на перекривні фрагменти, кожен з яких окремо опрацьовується детектором. На відміну від підходів, що виконують інференс лише на повному кадрі, така схема дає змогу підвищити помітність дрібних, віддалених і частково перекритих плодів. Подальше перенесення координат у систему вихідного зображення та глобальна постобробка результатів забезпечують формування єдиної множини детекцій без дублювання рамок у зонах перекриття.

Відмінність розробленого підходу від типових рішень полягає в тому, що задача не зводиться до класифікації окремого плода або загального визначення стану всього зображення. Метод орієнтований на отримання структурованої інформації про кожен плід у кадрі, що включає його просторове положення, стадію зрілості та рівень упевненості. Крім того, на відміну від рішень, які переважно оцінюють загальну точність розпізнавання, у межах цієї роботи акцент зроблено на повноті виявлення, оскільки пропущені плоди не потрапляють до подальшого аналізу та можуть спотворювати оцінку фактичного стану врожаю.

## Розділ 3 Експериментальне дослідження методу

### 3.1 Опис застосування та архітектура системи нейромережевої ідентифікації стадій зрілості плодів полуниці

Програмну систему Strawberry SAHI Vision, призначену для нейромережевого виявлення та ідентифікації стадій зрілості плодів полуниці за RGB-зображеннями тепличного середовища розроблено в межах виконання кваліфікаційної роботи бакалавра. Система реалізує повний цикл опрацювання даних: підключення набору зображень, підготовку розмітки, донавчання моделі YOLO11n, виконання базового та фрагментованого інференсу, постобробку детекцій, візуалізацію результатів і формування кількісної аналітики для оцінювання стану плодів.

Програмний засіб реалізовано як Python-застосунок у середовищі Google Colab [41] із використанням вебінтерфейсу Gradio [42]. Такий варіант реалізації є доцільним для експериментального дослідження, оскільки не потребує локального розгортання серверної частини, забезпечує доступ до бібліотек комп'ютерного зору та глибокого навчання, а також дозволяє за наявності відповідного runtime використовувати GPU / CUDA для пришвидшення навчання та інференсу. Користувач взаємодіє із системою через браузерний інтерфейс, у якому передбачено окремі вкладки для роботи з даними, навчання моделі, виконання інференсу, перегляду аналітики та налаштування методу SAHI.

Особливістю реалізації є те, що система побудована не як класичний об'єктно-орієнтований застосунок із набором окремих класів у коді, а як функціональний Python-застосунок, у якому окремі групи функцій відповідають за різні етапи обробки. Тому для опису внутрішньої структури доцільно використовувати діаграму логічних класів, яка не стверджує наявність відповідних класів у вихідному коді, а групує фактично реалізовані функції за їхніми відповідальностями. Діаграму логічних класів програмної системи Strawberry SAHI Vision наведено на рисунку 3.1.




Рисунок 3.1 – Діаграма логічних класів програмної системи Strawberry SAHI Vision

Як видно з рисунка 3.1, центральним логічним компонентом системи є StrawberryVisionApp, який відповідає за побудову інтерфейсу Gradio та координацію основних сценаріїв роботи: підготовки даних, навчання моделі, інференсу та оцінювання результатів. Компонент DataConnectionService узагальнює функції підключення даних із різних джерел, зокрема Kaggle, ZIP-архіву та файлу data.yaml. До його відповідальності належать завантаження або розпакування набору даних, пошук конфігураційного файлу та перевірка структури даних.

Компонент AnnotationPreparationService відповідає за підготовку розмітки до формату, придатного для навчання детектора об'єктів. У межах цього компонента реалізуються функції перетворення рядків YOLO-розмітки у прямокутні обмежувальні рамки, конвертації анотацій у формат детекції та формування навчальної, валідаційної й тестової вибірок. Це є важливим етапом, оскільки якість підготовки розмітки безпосередньо впливає на коректність подальшого навчання та оцінювання моделі.

Компонент `ModelTrainingService` узагальнює функції донавчання `YOLO11n` [43], завантаження моделі та збереження найкращих ваг. У свою чергу, `ModelCacheStorage` відповідає за роботу з кешем моделі, файлом `best.pt`, каталогом результатів `/content/runs` та збереженням ваг у `Google Drive`. Такий поділ дозволяє відокремити логіку навчання від логіки зберігання й повторного використання навчених ваг.

Для виконання інференсу в системі передбачено два логічні сервіси. `BaselineInferenceService` відповідає за обробку повного зображення за допомогою `YOLO`-моделі, побудову візуалізації знайдених об'єктів і формування таблиці детекцій. `SahiInferenceService` реалізує фрагментований інференс, тобто нарізку зображення на фрагменти, виконання передбачень на кожному фрагменті та об'єднання результатів за допомогою постобробки. Параметри інференсу, зокрема режим роботи, пороги `confidence` та `IoU`, розмір фрагмента й коефіцієнт перекриття, узагальнено у компоненті `InferenceConfig`.

Окремий логічний компонент `DetectionResult` описує результат виявлення одного плода: координати рамки, клас зрілості, рівень довіри та табличне подання результату. На основі множини таких результатів формуються подальші аналітичні й візуальні матеріали. Компонент `DatasetStatisticsService` відповідає за статистику набору даних, зокрема розподіл класів і площі обмежувальних рамок. `EvaluationService` використовується для оцінювання якості методу за метриками `precision`, `recall`,  $F_1$  та для порівняння базового й `SAHI`-режимів. `AnalyticsVisualizationService` забезпечує побудову анотованих зображень, графіків класів і експорт результатів у вигляді `PNG`- та `CSV`-файлів.

Отже, діаграма логічних класів відображає внутрішню організацію програмного засобу на рівні відповідальностей. Вона показує, що система складається з окремих функціональних блоків, які послідовно забезпечують підключення даних, підготовку розмітки, навчання моделі, виконання інференсу, формування результатів і їх аналітичну інтерпретацію. Такий підхід відповідає фактичній функціональній реалізації коду й водночас дозволяє описати систему в термінах проєктування програмного забезпечення.

Для опису фізичної та програмної організації системи використано діаграму розгортання. Вона відображає, у якому середовищі виконується застосунок, які зовнішні ресурси залучаються та як відбувається обмін даними між користувачем, середовищем виконання, джерелами даних і вихідними артефактами. Діаграму розгортання програмної системи Strawberry SAHI Vision наведено на рисунку 3.2.

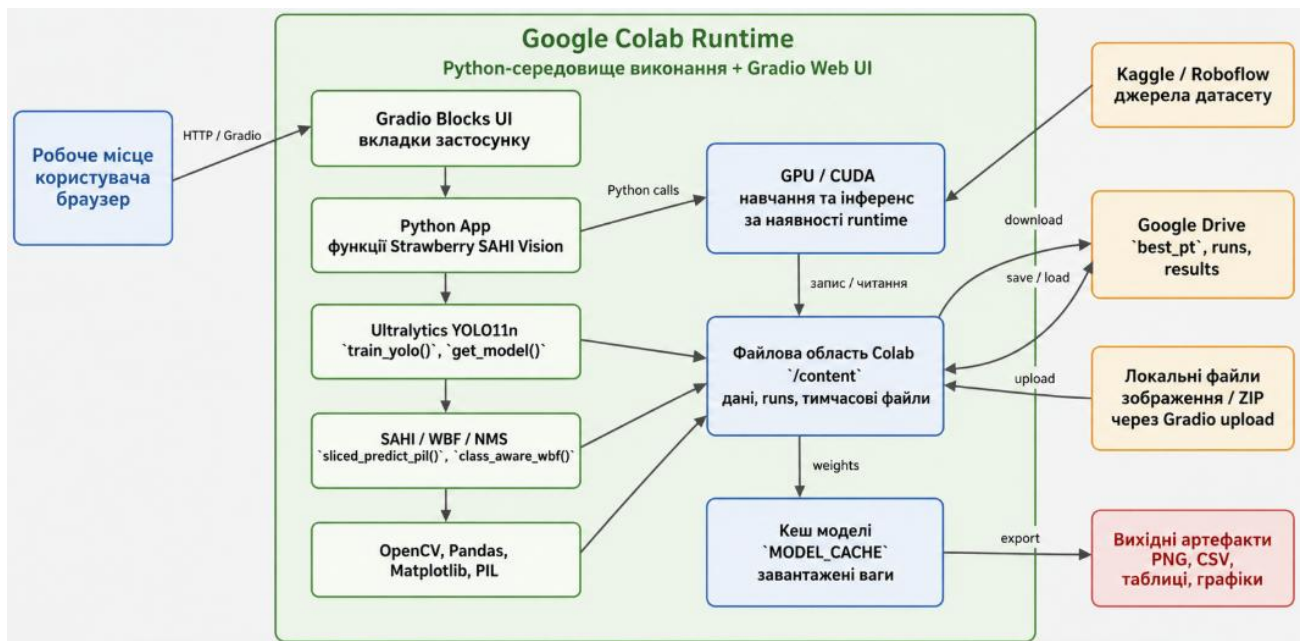


Рисунок 3.2 – Діаграма розгортання програмної системи Strawberry SAHI Vision

Як видно з рисунка 3.2, користувач працює із системою через браузер, який взаємодіє з інтерфейсом Gradio за допомогою HTTP-з'єднання. Уся основна логіка застосунку виконується в середовищі Google Colab Runtime, яке в цій реалізації виконує роль серверного середовища. Усередині Colab розміщено Gradio Blocks UI, Python-застосунок із функціями Strawberry SAHI Vision, модель Ultralytics YOLO11n, модулі SAHI / WBF / NMS, а також бібліотеки OpenCV, Pandas, Matplotlib і PIL, які використовуються для обробки зображень, формування таблиць і побудови графіків.

Окремо на діаграмі показано обчислювальний ресурс GPU / CUDA, який використовується для навчання та інференсу за наявності відповідного runtime у Google Colab. Це уточнення є важливим, оскільки застосунок може запускатися і в CPU-режимі, однак використання GPU істотно пришвидшує навчання моделі та обробку зображень. Файлова область Colab /content використовується для

збереження тимчасових даних, підготовленого набору, результатів навчання, проміжних файлів і каталогів runs. Окремо виділено кеш моделі MODEL\_CACHE, у якому зберігаються завантажені або повторно використані ваги.

Зовнішніми джерелами даних є Kaggle / Roboflow, з яких може завантажуватися набір даних, а також локальні файли користувача, що передаються через Gradio upload у вигляді зображення або ZIP-архіву. Google Drive використовується як зовнішнє сховище для збереження файлу best.pt, каталогів запусків і результатів. Така організація дозволяє не втрачати навчені ваги після завершення сесії Colab і повторно використовувати їх для інференсу або подальших експериментів.

Вихідними артефактами роботи системи є анотовані зображення, CSV-таблиці детекцій, графіки розподілу класів, таблиці з метриками та інші результати оцінювання. Таким чином, система формує не лише візуальне подання знайдених плодів, а й структуровану інформацію, придатну для подальшого аналізу. Це дає змогу використовувати застосунок як інструмент експериментального дослідження методу нейромережевої ідентифікації стадій зрілості плодів полуниці.

Запропонована архітектура має кілька практичних переваг. По-перше, вона не потребує окремого серверного розгортання, оскільки вся логіка виконується в Google Colab. По-друге, використання Gradio забезпечує зручний вебінтерфейс для користувача без необхідності безпосередньо змінювати код. По-третє, підтримка різних джерел даних дозволяє використовувати як публічні набори, так і власні зображення. По-четверте, наявність двох режимів інференсу дає змогу порівнювати базовий YOLO-підхід із фрагментованим SAHI-режимом, що важливо для перевірки впливу фрагментації на повноту виявлення дрібних плодів.

Для уточнення відповідності між архітектурними компонентами системи та фактично реалізованими функціями коду доцільно подати узагальнене

зіставлення основних етапів роботи застосунку Strawberry SAHI Vision, наведене в таблиці 3.1.

Таблиця 3.1 – Відповідність етапів роботи системи реалізованим функціям коду

<b>Етап роботи системи</b>	<b>Функції коду</b>	<b>Призначення</b>
Підключення та підготовка даних	download_kaggle(), unpack_dataset(), find_data_yaml(), create_detection_split_from_all()	Завантаження даних, перевірка структури, підготовка розмітки та формування train / val вибірок.
Навчання та робота з моделлю	train_yolo(), get_model(), load_weights(), copy_to_drive()	Донавчання YOLO11n, завантаження, кешування та збереження ваг моделі.
Інференс зображень	yolo_predict_pil(), generate_slices(), sliced_predict_pil()	Виконання базового YOLO-інференсу та фрагментованого SAHI-інференсу.
Постобробка та візуалізація	class_aware_wbf(), draw_detections(), detections_dataframe()	Об'єднання дублюючих рамок, побудова анотованого зображення та таблиці детекцій.
Аналітика й оцінювання	dataset_stats(), evaluate_method()	Розрахунок статистики датасету, метрик якості та порівняння baseline / SAHI.

Наведене зіставлення показує, що реалізований застосунок охоплює повний цикл нейромережевої ідентифікації стадій зрілості плодів полуниці: від підключення та підготовки даних до навчання моделі, виконання базового й фрагментованого інференсу, постобробки детекцій, візуалізації результатів та оцінювання якості. Це підтверджує узгодженість програмної реалізації з розробленою архітектурою системи та демонструє, що кожен функціональний етап методу має відповідне відображення у коді.

На рисунку 3.3 наведено інтерфейс розробленого застосунку.

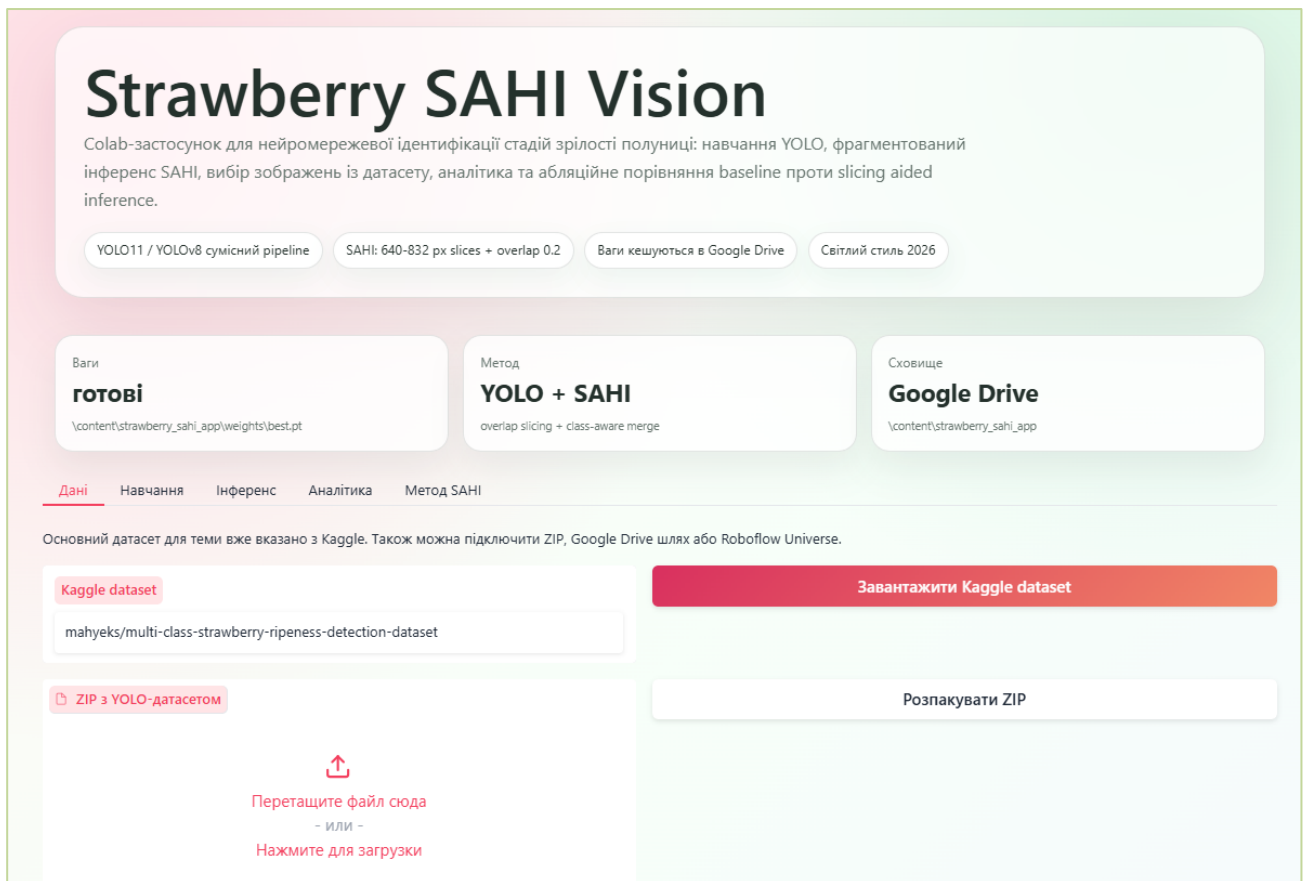


Рисунок 3.3 – Інтерфейс розробленої системи

Отже, у межах програмної реалізації сформовано модульну систему, яка поєднує підготовку даних, донавчання YOLO-моделі, базовий і фрагментований інференс, постобробку детекцій, оцінювання якості та візуалізацію результатів. Подані діаграми дозволяють описати систему з двох позицій: діаграма логічних класів відображає внутрішнє групування функціональних відповідальностей, а діаграма розгортання – середовище виконання та взаємодію із зовнішніми ресурсами. Така структура забезпечує можливість відтворення експериментів і створює основу для подальшої інтеграції системи в автономні або напівавтономні тепличні комплекси.

### 3.2 Аналіз результатів навчання та тестування YOLO-моделі

Для експериментальної перевірки реалізованого методу використано модель YOLO11n, ініціалізовану попередньо навченими вагами та донавчену на підготовленому наборі даних із трьома класами зрілості плодів полуниці.

Локальний контрольний запуск виконано протягом 4 епох, тому наведені результати доцільно розглядати як експериментальне підтвердження працездатності реалізованого конвеєра та попередню оцінку якості моделі, а не як остаточну промислову конфігурацію системи.

У межах експерименту оцінювалися динаміка навчання, якість роботи моделі на тестовій вибірці, характер похибок між класами зрілості та вплив фрагментованого SAHI-інференсу на результати виявлення. Підсумкові показники локального навчання YOLO11n наведено в таблиці 3.2.

Таблиця 3.2 – Підсумкові показники локального навчання YOLO11n

Показник	Значення
Епохи навчання	4
Precision(B)	0,6348
Recall(B)	0,7151
mAP@50(B)	0,7019
mAP@50:95(B)	0,5267
train/box_loss	1,0607
val/box_loss	0,9896

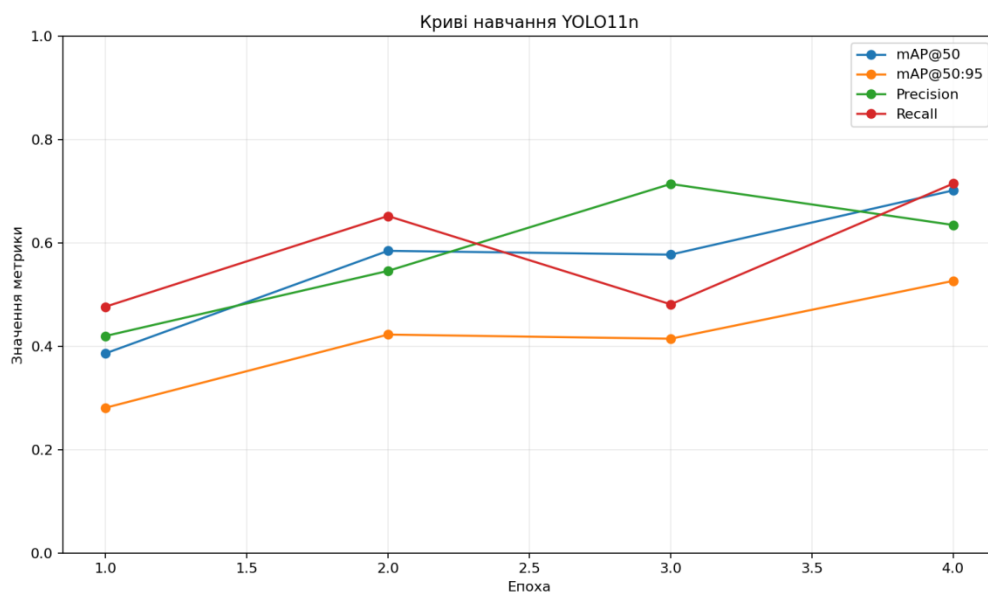


Рисунок 3.4 – Криві навчання моделі YOLO11n за метриками precision, recall, mAP@50 та mAP@50:95

Аналіз кривих навчання на рисунку 3.4 показує, що навіть за короткого навчання модель швидко адаптується до предметної області. Значення  $mAP@50$  зросло з 0,3862 на першій епісі до 0,7019 на четвертій, а  $mAP@50:95$  збільшилося до 0,5267. Одночасно зменшилися втрати локалізації:  $train/box\_loss$  знизився до 1,0607, а  $val/box\_loss$  – до 0,9896. Це свідчить про формування моделлю здатності локалізувати плоди полуниці та розрізняти їх за стадіями зрілості.

Водночас коротка тривалість навчання обмежує стабільність отриманих результатів. Значення  $precision$  і  $recall$  змінюються нерівномірно, що є типовим для ранніх етапів донавчання моделі на відносно невеликому наборі даних. Тому подальше підвищення якості очікувано потребує збільшення кількості епох, використання GPU-навчання та додаткового налаштування гіперпараметрів. Оцінювання на тестовій вибірці дало результати, наведені в таблиці 3.3.

Таблиця 3.3 – Точність моделі YOLO11n на тестовій вибірці за класами

Клас	Зображення	Об'єкти	Precision	Recall	$mAP@50$	$mAP@50:95$
all	57	179	0,642	0,669	0,642	0,466
ripe	33	50	0,656	0,740	0,694	0,552
partially_ripe	18	25	0,465	0,661	0,572	0,430
unripe	47	104	0,805	0,606	0,661	0,415

Загальні результати на тестовій вибірці становлять  $precision = 0,642$ ,  $recall = 0,669$ ,  $mAP@50 = 0,642$  та  $mAP@50:95 = 0,466$ . Для поставленої мети особливе значення має показник  $recall$ , оскільки він характеризує повноту виявлення плодів. Отримане значення  $recall = 0,669$  підтверджує, що модель здатна знаходити більшість розмічених плодів у тестових зображеннях, однак частина об'єктів усе ще залишається невиявленою.

Найкраще модель розпізнає клас «ripe», для якого отримано  $recall = 0,740$  та  $mAP@50 = 0,694$ . Це пояснюється більш виразними візуальними ознаками стиглих плодів, насамперед насиченим червоним забарвленням. Клас «unripe» має найвище значення  $precision = 0,805$ , але нижчий  $recall = 0,606$ , тобто модель порівняно рідко помилково відносить інші об'єкти до нестиглих, однак частину нестиглих плодів пропускає. Найскладнішим є клас `partially_ripe`, що має проміжні колірні ознаки та найменшу кількість прикладів у наборі даних.




Рисунок 3.5 – Матриця помилок моделі YOLO11n на тестовій вибірці

Матриця помилок на рисунку 3.5 деталізують характер взаємних змішувань між класами. Основна зона ризику пов'язана з перехідною стадією зрілості, оскільки напівстигли плоди можуть мати ознаки як стиглого, так і нестиглого класу. Такі помилки мають практичне значення: віднесення напівстиглого плода до стиглого може спричинити передчасний збір, тоді як віднесення до нестиглого – відтермінування збору.

Для аналізу співвідношення точності та повноти побудовано precision-recall криві за класами зрілості, наведені на рисунку 3.6.

Precision-recall крива підтверджує різну складність класів. Для класу ripe площа під кривою є найбільшою, що відповідає вищим значенням mAP. Для класу partially\_ripe крива швидше втрачає точність зі зростанням recall, що відображає складність розпізнавання проміжної стадії зрілості. Це узгоджується з результатами таблиці 3.3 і матрицею помилок.




Рисунок 3.6 – Precision-Recall крива для класів зрілості плодів полуниці

Приклад передбачень моделі на тестових зображеннях наведено на рисунку 3.7. Візуальний аналіз показує, що модель здатна знаходити плоди в умовах складного тепличного фону, однак для частково перекритих або малих об'єктів імовірність пропуску залишається вищою.



Рисунок 3.8 – Приклад передбачень моделі YOLO11n на тестових зображеннях

Для перевірки впливу фрагментованого інференсу на повноту виявлення було проаналізовано 60 зображень. Приклад зображень, для яких SAPH-інференс підвищив повноту виявлення плодів наведено у таблиці 3.4.

Таблиця 3.4 – Порівняння значень метрики Recall для вибірки тестових зображень

№	YOLO Recall	SAHI TP / Det	SAHI Recall	Приріст Recall
1	0,4000	10 / 40	1,0000	+0,6000
2	0,2000	13 / 41	0,6500	+0,4500
3	0,4167	10 / 35	0,8333	+0,4167
4	0,2667	10 / 37	0,6667	+0,4000
5	0,1250	4 / 27	0,5000	+0,3750
6	0,5000	12 / 27	0,8571	+0,3571
7	0,6667	6 / 40	1,0000	+0,3333
8	0,5000	5 / 32	0,8333	+0,3333
9	0,3333	4 / 28	0,6667	+0,3333
10	0,3077	8 / 34	0,6154	+0,3077
11	0,4000	7 / 53	0,7000	+0,3000
12	0,6429	13 / 31	0,9286	+0,2857
13	0,5714	6 / 30	0,8571	+0,2857
14	0,6000	8 / 33	0,8000	+0,2000
15	0,6000	8 / 37	0,8000	+0,2000
16	0,6667	5 / 43	0,8333	+0,1667
17	0,5833	9 / 41	0,7500	+0,1667
18	0,5000	4 / 41	0,6667	+0,1667
19	0,2857	3 / 66	0,4286	+0,1429
20	0,8750	8 / 39	1,0000	+0,1250

Як видно з таблиці 3.4, на окремих зображеннях фрагментований SAHI-інференс забезпечує суттєве зростання повноти виявлення плодів порівняно з baseline YOLO. Найбільший приріст Recall становить від +0,6000 до +0,3000 для зображень зі значною кількістю плодів або складними умовами візуального представлення. Водночас збільшення кількості детекцій у SAHI-режимі свідчить про необхідність подальшого налаштування порогу довіри, IoU та параметрів об'єднання рамок, щоб зберегти приріст повноти без надмірного зростання кількості хибних спрацювань.

Також було проведено візуальне порівняння результатів baseline YOLO-інференсу та SAPH-інференсу на одному контрольному RGB-зображенні тепличної сцени. Метою такого порівняння було не лише зіставити кількість знайдених об'єктів, а й оцінити характер помилок, зокрема наявність хибних спрацювань на фонових елементах сцени.

Результат baseline YOLO-інференсу наведено на рисунку 3.9. У цьому режимі модель виявила 11 об'єктів за 0,22 с. Формально такий результат свідчить про більшу кількість детекцій, однак візуальний аналіз анотованого зображення показує, що частина рамок не відповідає реальним плодам полуниці. Зокрема, окремі детекції розміщені на ділянках фону, ґрунту, листя або слабоінформативних фрагментах зображення, де об'єкт класу «плід полуниці» фактично відсутній. Отже, baseline YOLO у цьому прикладі має схильність до хибних позитивних спрацювань, що може збільшувати кількість знайдених об'єктів, але не обов'язково підвищує якість результату.



Рисунок 3.9 – Результат baseline YOLO-інференсу на контрольному зображенні

На рисунку 3.9 також видно, що модель сформувала детекції для трьох класів зрілості: unripe, ripe та partially\_ripe. Проте наявність класу в результаті не гарантує коректності кожної окремої рамки, оскільки частина передбачень може бути результатом помилкового спрацювання на фонових областях. Тому для

оцінювання якості такого результату недостатньо враховувати лише кількість детекцій або Recall; необхідно також аналізувати Precision, тобто частку справді коректних спрацювань серед усіх передбачених рамок.

Результат SAHI-інференсу наведено на рисунку 3.10. У цьому режимі система сформувала 7 фінальних детекцій за 0,21 с. Порівняно з baseline YOLO кількість рамок зменшилася, однак візуально результат виглядає більш стриманим і менш перевантаженим хибними спрацюваннями. SAHI-режим у цьому прикладі не просто зменшив кількість детекцій, а відфільтрував частину сумнівних передбачень, які в baseline-режимі були розміщені на фонових елементах сцени.

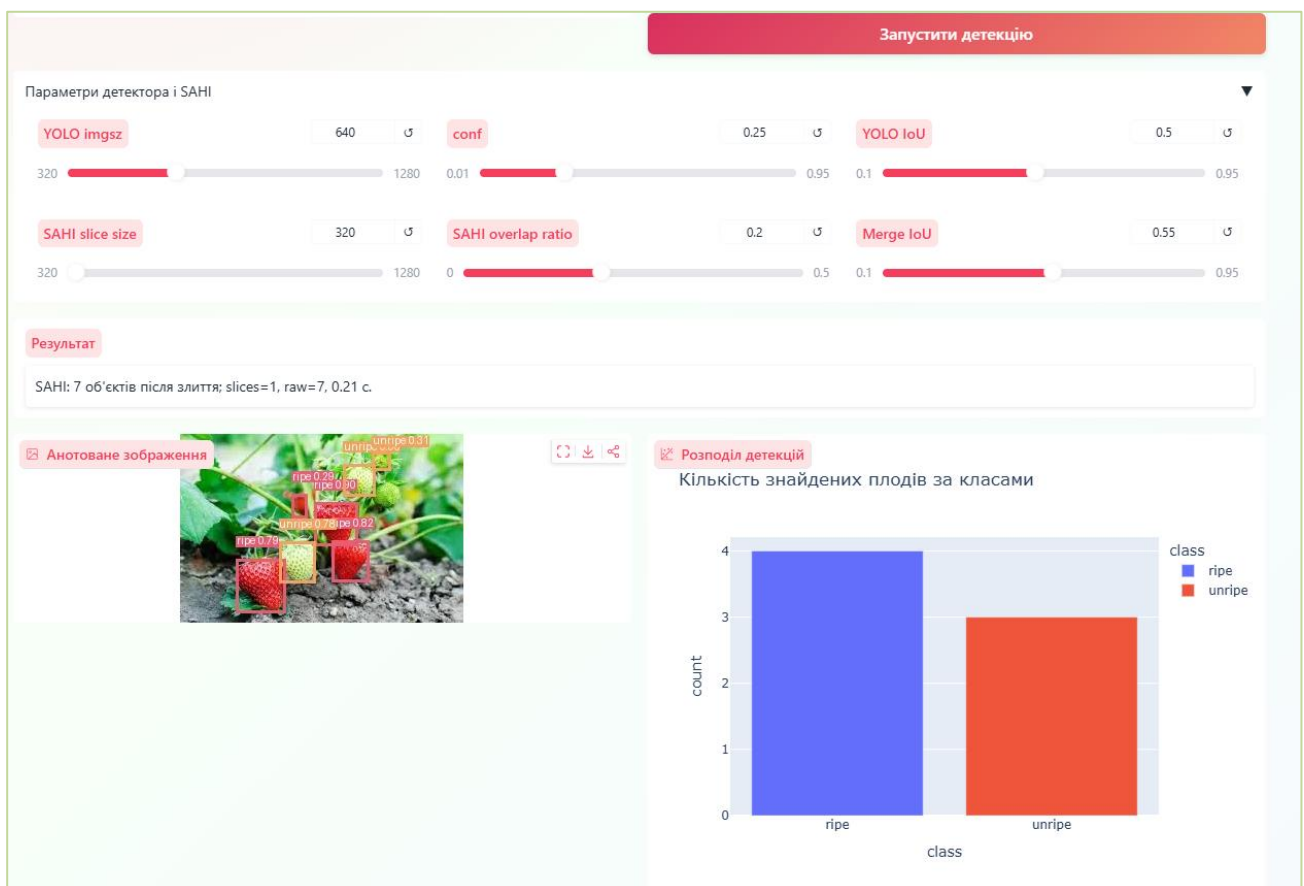


Рисунок 3.10 – Результат SAHI-інференсу на контрольному зображенні

Порівняння рисунків 3.9 і 3.10 показує, що для задачі ідентифікації стадій зрілості плодів полуниці важливо аналізувати не лише кількість детекцій, а й їхню фактичну коректність. Більша кількість рамок у baseline YOLO може створювати враження вищої повноти, однак за наявності хибних спрацювань така перевага є формальною. SAHI-режим у наведеному прикладі дозволяє

отримати більш компактний результат із меншою кількістю очевидних фонових детекцій.

Отже, фрагментований інференс підвищує чутливість до локальних деталей і може бути корисним для дрібних або віддалених плодів, однак його ефективність залежить від якості базового детектора, порогу довіри, розміру фрагмента, коефіцієнта перекриття та параметрів об'єднання рамок. У реалізованому застосунку ці параметри винесено в інтерфейс, що дає можливість проводити подальші абляційні експерименти.

### **3.3 Обмеження методу та напрямки вдосконалення**

Розроблений метод нейромережевої ідентифікації стадій зрілості плодів полуниці за RGB-зображеннями забезпечує автоматизоване виявлення плодів, визначення їхнього класу зрілості та формування структурованих результатів для подальшого аналізу. Водночас результати експериментального дослідження показали, що якість роботи методу істотно залежить від умов зйомки, структури навчального набору, параметрів інференсу та складності тепличної сцени.

Основним обмеженням є обмежений обсяг і дисбаланс використаного набору даних. Попри наявність реальних RGB-зображень тепличного середовища, датасет не охоплює всіх можливих варіантів освітлення, ракурсів, сортових особливостей, ступенів перекриття плодів і фаз дозрівання. Найбільш проблемним є клас `partially_ripe`, оскільки він має проміжні візуальні ознаки між стиглими та нестиглими плодами. Це ускладнює його відокремлення від сусідніх класів і може призводити до помилок класифікації.

Метод також є чутливим до якості RGB-зображення. Нерівномірне освітлення, тіні, відблиски, листя, ґрунт і часткові перекриття можуть спричиняти як пропуск реальних плодів, так і хибні позитивні спрацювання. Візуальний аналіз результатів показав, що `baseline YOLO` іноді формує рамки на фонових ділянках, де фактичний плід відсутній. Тому збільшення кількості детекцій не завжди означає покращення якості: разом із `Recall` необхідно контролювати `Precision` і характер помилкових спрацювань.

Окремим обмеженням є залежність SANE-інференсу від параметрів нарізки та постобробки. На окремих зображеннях фрагментований інференс підвищує повноту виявлення дрібних або частково перекритих плодів, однак в інших випадках може зменшувати кількість фінальних детекцій або втрачати менш упевнені передбачення. Це означає, що SANE не є універсальним механізмом гарантованого покращення, а потребує підбору параметрів `conf`, `IoU`, `slice_size`, `overlap` і `merge IoU` для конкретних умов зйомки та характеристик датасету.

Ще одним обмеженням є експериментальний характер програмної реалізації. Система створена у середовищі Google Colab із вебінтерфейсом Gradio, що є зручним для навчання, тестування та демонстрації, але не є повноцінним промисловим розгортанням для безперервної роботи в теплиці. Робота застосунку залежить від доступності runtime, типу обчислювального ресурсу та стану сесії Colab. Для практичного впровадження потрібне перенесення системи у стабільне середовище виконання, наприклад на локальний сервер, edge-пристрій або вбудовану платформу з підключенням до камери.

Подальше вдосконалення методу доцільно спрямувати на розширення та балансування набору даних, зокрема збільшення кількості прикладів класу `partially_ripe` і додавання складних негативних прикладів із листям, ґрунтом, тінями та іншими фоновими об'єктами. Це дозволить зменшити кількість хибних спрацювань і підвищити стійкість моделі до складних тепличних сцен. Доцільним є також систематичний підбір параметрів baseline YOLO та SANE-режиму з урахуванням не лише mAP, а й Precision, Recall, F1 та часу обробки зображення.

Перспективним напрямом є порівняння YOLO11n з іншими конфігураціями YOLO та моделями, краще адаптованими до малих об'єктів. Додатково можна застосувати розширені аугментації, балансування класів, донавчання на складних випадках і механізми зменшення хибних позитивних спрацювань. Для практичного використання в тепличному комплексі варто перейти від аналізу окремих зображень до аналізу послідовностей кадрів із

трекінгом плодів, що дозволить стабілізувати результати та оцінювати динаміку дозрівання.

Отже, основними обмеженнями розробленого методу є залежність від якості RGB-зображень, дисбаланс класів, складність розпізнавання проміжної стадії зрілості, хибні позитивні спрацювання та чутливість SAHI до параметрів інференсу. Подальше розширення датасету, налаштування параметрів, удосконалення моделі та перехід до стабільного розгортання можуть підвищити повноту й надійність нейромережевої ідентифікації стадій зрілості плодів полуниці в умовах тепличного середовища.

### 3.4 Висновки до розділу 3

У третьому розділі виконано експериментальне дослідження методу нейромережевої ідентифікації стадій зрілості плодів полуниці за RGB-зображеннями та розроблено програмну систему Strawberry SAHI Vision для його практичної реалізації. Система забезпечує повний цикл роботи з даними: підключення набору зображень, підготовку розмітки, донавчання YOLO11n, виконання базового та фрагментованого інференсу, постобробку детекцій, візуалізацію результатів і розрахунок метрик якості. Подані діаграми логічних класів і розгортання підтверджують, що програмна реалізація має модульну структуру та відповідає основним етапам розробленого методу.

У межах експериментального дослідження проведено локальне донавчання YOLO11n на підготовленому наборі даних із трьома класами зрілості плодів полуниці. Отримані результати підтвердили працездатність реалізованого конвеєра: після 4 епох навчання модель досягла  $\text{Precision(B)} = 0,6348$ ,  $\text{Recall(B)} = 0,7151$ ,  $\text{mAP@50(B)} = 0,7019$  та  $\text{mAP@50:95(B)} = 0,5267$ . Зменшення  $\text{train/box\_loss}$  і  $\text{val/box\_loss}$  свідчить про здатність моделі поступово адаптуватися до задачі локалізації плодів у тепличних RGB-зображеннях.

Оцінювання на тестовій вибірці показало, що модель YOLO11n забезпечила загальні значення  $\text{precision} = 0,642$ ,  $\text{recall} = 0,669$ ,  $\text{mAP@50} = 0,642$  та  $\text{mAP@50:95} = 0,466$ . Для поставленої мети особливо важливим є значення

recall = 0,669, оскільки воно характеризує повноту виявлення плодів. Найкращі результати отримано для класу `ripe`, що пояснюється виразними візуальними ознаками стиглих плодів. Найскладнішим залишився клас `partially_ripe`, який має проміжні ознаки між стиглими та нестиглими плодами і є менш представленим у наборі даних.

Аналіз матриці помилок, precision-recall кривих і прикладів передбачень показав, що основні труднощі пов'язані з розпізнаванням напівстиглих плодів, частковими перекриттями, малим видимим розміром окремих об'єктів і складним фоном тепличної сцени. Візуальний аналіз також підтвердив, що більша кількість детекцій не завжди означає кращу якість результату, оскільки `baseline YOLO` може формувати хибні рамки на фонових ділянках, де фактичні плоди відсутні. Тому під час оцінювання методу необхідно враховувати не лише Recall, а й Precision та характер хибних позитивних спрацювань.

Дослідження фрагментованого SAHI-інференсу показало, що на окремих зображеннях він здатний суттєво підвищувати повноту виявлення плодів порівняно з `baseline YOLO`. У відібраних прикладах приріст Recall становив від +0,1250 до +0,6000, що підтверджує доцільність використання фрагментованого інференсу для складних сцен із дрібними або частково перекритими плодами. Водночас візуальне порівняння `baseline YOLO` та SAHI показало, що ефективність SAHI залежить від параметрів нарізки, порогу довіри, IoU та об'єднання рамок. Тому SAHI доцільно розглядати як додатковий режим інференсу, який потребує експериментального налаштування для досягнення балансу між повнотою виявлення та кількістю хибних спрацювань.

У розділі також визначено основні обмеження методу: залежність від якості RGB-зображень, дисбаланс класів, складність розпізнавання проміжної стадії зрілості, наявність хибних позитивних спрацювань і чутливість SAHI до параметрів інференсу. Подальше вдосконалення методу доцільно спрямувати на розширення й балансування набору даних, збільшення кількості прикладів класу `partially_ripe`, додавання складних негативних прикладів, систематичний підбір параметрів `baseline YOLO` та SAHI, а також перенесення системи з Google Colab у стабільне середовище для практичного розгортання.

## Загальні висновки

У кваліфікаційній роботі бакалавра розв'язано задачу підвищення повноти визначення стадій зрілості плодів полуниці за RGB-зображеннями в умовах тепличного середовища шляхом розроблення методу нейромережевої ідентифікації стадій зрілості плодів полуниці за зображеннями на основі донавченої YOLO-моделі, що забезпечує автоматичну локалізацію плодів, визначення їхньої стадії зрілості та формування аналітичної інформації для прийняття рішення щодо збору врожаю.

Мету досягнуто повністю, а для її досягнення було вирішено такі завдання:

- проведено огляд та аналіз сучасних інформаційних моделей, методів комп'ютерного зору та моделей глибокого навчання для задач виявлення плодів і визначення їхніх стадій зрілості за RGB-зображеннями;

- формалізовано задачу нейромережевого виявлення та ідентифікації стадій зрілості плодів полуниці як задачу багатокласової детекції об'єктів у RGB-зображеннях тепличного середовища;

- розроблено метод нейромережевого виявлення та класифікації плодів полуниці на основі донавченої YOLO-моделі, орієнтований на підвищення повноти ідентифікації стадій зрілості;

- реалізовано програмний засіб для опрацювання RGB-зображень, навчання моделі, виконання інференсу, візуалізації результатів і формування аналітичної інформації для прийняття рішення щодо збору врожаю;

- проведено експериментальне дослідження розробленого методу з оцінюванням якості виявлення та ідентифікації стадій зрілості плодів полуниці.

Напрями подальшого вдосконалення розробленого методу пов'язані насамперед із розширенням і балансуванням навчального набору даних. Доцільно збільшити кількість RGB-зображень, отриманих у різних тепличних умовах, за різного освітлення, ракурсів зйомки, ступенів перекриття плодів і для різних сортів полуниці. Особливої уваги потребує клас напівстиглих плодів,

оскільки він має проміжні візуальні ознаки та є найскладнішим для стабільного розпізнавання. Додавання більшої кількості прикладів цього класу, а також складних негативних прикладів із листям, ґрунтом, тіннями та іншими фоновими елементами дозволить зменшити кількість хибних спрацювань і підвищити надійність ідентифікації.

Перспективним напрямом є подальше налаштування параметрів базового YOLO-інференсу та фрагментованого SAPHI-інференсу. Зокрема, доцільно провести абляційні експерименти з різними значеннями порогу довіри, IoU, розміру фрагмента, коефіцієнта перекриття та параметрів об'єднання рамок. Це дозволить визначити конфігурацію, яка забезпечує найкращий баланс між повнотою виявлення плодів, точністю детекцій і часом обробки зображення. Оскільки фрагментований інференс може підвищувати повноту на окремих складних зображеннях, але водночас збільшувати кількість кандидатних рамок, його параметри мають добиратися з урахуванням практичних умов використання системи.

## Перелік посилань

1. Current state and future perspectives of commercial strawberry production: A review / N. R. Hernández-Martínez та ін. *Scientia Horticulturae*. 2023. Т. 312. С. 111893. URL: <https://doi.org/10.1016/j.scienta.2023.111893> (дата звернення: 08.06.2026).
2. 3D-based precise evaluation pipeline for maize ear rot using multi-view stereo reconstruction and point cloud semantic segmentation / R. Yang et al. *Computers and Electronics in Agriculture*. 2024. Vol. 216. P. 108512. URL: <https://doi.org/10.1016/j.compag.2023.108512> (date of access: 08.06.2026).
3. Saad A., Azam M. M., Amer B. M. A. Quality Analysis Prediction and Discriminating Strawberry Maturity with a Hand-held Vis–NIR Spectrometer. *Food Analytical Methods*. 2021. Т. 15, № 3. С. 689–699. URL: <https://doi.org/10.1007/s12161-021-02166-2> (дата звернення: 08.06.2026).
4. Prediction of Strawberry Quality during Maturity Based on Hyperspectral Technology / L. Fan et al. *Agronomy*. 2024. Vol. 14, no. 7. P. 1450. URL: <https://doi.org/10.3390/agronomy14071450> (date of access: 08.06.2026).
5. Determining Strawberries' Varying Maturity Levels by Utilizing Image Segmentation Methods of Improved DeepLabV3+ / C. Cai et al. *Agronomy*. 2022. Vol. 12, no. 8. P. 1875. URL: <https://doi.org/10.3390/agronomy12081875> (date of access: 08.06.2026).
6. Analysis of physicochemical and phytonutrients properties of bastard oleaster fruits and its mass prediction using artificial neural network model / R. Sasikumar et al. *Journal of Agriculture and Food Research*. 2024. P. 101224. URL: <https://doi.org/10.1016/j.jafr.2024.101224> (date of access: 08.06.2026).
7. Chai J. J. K., Xu J.-L., O'Sullivan C. Real-Time Detection of Strawberry Ripeness Using Augmented Reality and Deep Learning. *Sensors*. 2023. V. 23, № 17. P. 7639. URL: <https://doi.org/10.3390/s23177639> (дата звернення: 08.06.2026).

8. Application Of K-Means Clustering Algorithm to Identify the Best-Selling Digital Printing Services / A. Fatahali Ramadhan et al. *Indonesian Journal of Data and Science*. 2025. Vol. 6, no. 3. P. 356–369. URL: <https://doi.org/10.56705/ijodas.v6i3.316> (date of access: 08.06.2026).

9. Mo Y., Bai S., Chen W. ASHM-YOLOv9: A Detection Model for Strawberry in Greenhouses at Multiple Stages. *Applied Sciences*. 2025. Vol. 15, no. 15. P. 8244. URL: <https://doi.org/10.3390/app15158244> (date of access: 08.06.2026).

10. Strawberry Maturity Recognition Based on Improved YOLOv5 / Z. Tao et al. *Agronomy*. 2024. Vol. 14, no. 3. P. 460. URL: <https://doi.org/10.3390/agronomy14030460> (date of access: 08.06.2026).

11. Classification of strawberry ripeness stages using machine learning algorithms and colour spaces / S. Karki et al. *Horticulture, Environment, and Biotechnology*. 2023. URL: <https://doi.org/10.1007/s13580-023-00559-2> (date of access: 08.06.2026).

12. Effect of air temperature on each fruit growth and ripening stage of strawberry ‘Koiminori’ / H. Naito et al. *International Agrophysics*. 2024. Vol. 38, no. 2. P. 195–202. URL: <https://doi.org/10.31545/intagr/185988> (date of access: 08.06.2026).

13. 李 柁. Research on Strawberry Maturity Detection Algorithm Based on Improved YOLOv8. *Journal of Sensor Technology and Application*. 2025. Vol. 13, no. 06. P. 934–944. URL: <https://doi.org/10.12677/jsta.2025.136091> (date of access: 08.06.2026).

14. Biochemical Dynamics and Quality Attributes of Strawberry Fruits across Maturity Stages with Respect to Different Preservation Methods / M. M. Ahmed et al. *Futuristic Biotechnology*. 2024. P. 28–35. URL: <https://doi.org/10.54393/fbt.v4i01.98> (date of access: 08.06.2026).

15. Strawberry ripeness detection based on YOLOv8 algorithm fused with LW-Swin Transformer / S. Yang et al. *Computers and Electronics in Agriculture*.

2023. Vol. 215. P. 108360. URL: <https://doi.org/10.1016/j.compag.2023.108360> (date of access: 08.06.2026).

16. Rapid and Non-Destructive Techniques for the Discrimination of Ripening Stages in Candonga Strawberries / M. Palumbo et al. *Foods*. 2022. Vol. 11, no. 11. P. 1534. URL: <https://doi.org/10.3390/foods11111534> (date of access: 08.06.2026).

17. State-of-the-Art Techniques for Fruit Maturity Detection / J. Ma et al. *Agronomy*. 2024. Vol. 14, no. 12. P. 2783. URL: <https://doi.org/10.3390/agronomy14122783> (date of access: 08.06.2026).

18. Saleem M. H., Potgieter J., Arif K. M. Automation in Agriculture by Machine and Deep Learning Techniques: A Review of Recent Developments. *Precision Agriculture*. 2021. URL: <https://doi.org/10.1007/s11119-021-09806-x> (date of access: 08.06.2026).

19. Assisting the Planning of Harvesting Plans for Large Strawberry Fields through Image-Processing Method Based on Deep Learning / C. Wang et al. *Agriculture*. 2024. Vol. 14, no. 4. P. 560. URL: <https://doi.org/10.3390/agriculture14040560> (date of access: 08.06.2026).

20. Fruit Detection and Recognition Based on Deep Learning for Automatic Harvesting: An Overview and Review / F. Xiao et al. *Agronomy*. 2023. Vol. 13, no. 6. P. 1625. URL: <https://doi.org/10.3390/agronomy13061625> (date of access: 08.06.2026).

21. Comprehensive review of recent developments in visual object detection based on deep learning / E. Edozie et al. *Artificial Intelligence Review*. 2025. Vol. 58, no. 9. URL: <https://doi.org/10.1007/s10462-025-11284-w> (date of access: 08.06.2026).

22. From classical techniques to convolution-based models: A review of object detection algorithms / F. Neha et al. *2025 IEEE 6th International Conference on Image Processing, Applications and Systems (IPAS)*, Lyon, France, 9–11 January 2025. 2025. P. 1–6. URL: <https://doi.org/10.1109/ipas63548.2025.10924494> (date of access: 08.06.2026).

23. Muzammul M., Li X. Comprehensive review of deep learning-based tiny object detection: challenges, strategies, and future directions. *Knowledge and Information Systems*. 2025. URL: <https://doi.org/10.1007/s10115-025-02375-9> (date of access: 08.06.2026).
24. Object Detection in 20 Years: A Survey / Z. Zou et al. *Proceedings of the IEEE*. 2023. P. 1–20. URL: <https://doi.org/10.1109/jproc.2023.3238524> (date of access: 08.06.2026).
25. Comparative performance analysis of single-stage and two-stage object detectors and design of novel quantum-enhanced deep learning model for visually impaired / B. N. Rashmi et al. *Neural Computing and Applications*. 2025. URL: <https://doi.org/10.1007/s00521-025-11686-5> (date of access: 08.06.2026).
26. Deep learning-based image processing framework for efficient surface litter detection in Computer Vision applications / I. Shad et al. *Journal of Radiation Research and Applied Sciences*. 2025. Vol. 18, no. 2. P. 101534. URL: <https://doi.org/10.1016/j.jrras.2025.101534> (date of access: 08.06.2026).
27. Terven J., Córdova-Esparza D.-M., Romero-González J.-A. A Comprehensive Review of YOLO Architectures in Computer Vision: From YOLOv1 to YOLOv8 and YOLO-NAS. *Machine Learning and Knowledge Extraction*. 2023. Vol. 5, no. 4. P. 1680–1716. URL: <https://doi.org/10.3390/make5040083> (date of access: 08.06.2026).
28. Starting from the structure: A review of small object detection based on deep learning / Z. Xiuling et al. *Image and Vision Computing*. 2024. Vol. 146. P. 105054. URL: <https://doi.org/10.1016/j.imavis.2024.105054> (date of access: 08.06.2026).
29. Yue Y., Xu S., Wu H. A Strawberry Ripeness Detection Method Based on Improved YOLOv8. *Applied Sciences*. 2025. Vol. 15, no. 11. P. 6324. URL: <https://doi.org/10.3390/app15116324> (date of access: 08.06.2026).
30. YOLOv11-GSF: an optimized deep learning model for strawberry ripeness detection in agriculture / H. Ma et al. *Frontiers in Plant Science*. 2025. Vol. 16. URL: <https://doi.org/10.3389/fpls.2025.1584669> (date of access: 08.06.2026).

31. Generalized Intersection Over Union: A Metric and a Loss for Bounding Box Regression / H. Rezatofighi et al. *2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, Long Beach, CA, USA, 15–20 June 2019. 2019. URL: <https://doi.org/10.1109/cvpr.2019.00075> (date of access: 08.06.2026).
32. Yurdakul M. Multi-Class Strawberry Ripeness Detection Dataset. 2026. URL: <https://doi.org/10.21227/dmwm-sc17>.
33. Focal Loss for Dense Object Detection / T.-Y. Lin et al. *2017 IEEE International Conference on Computer Vision (ICCV)*, Venice, 22–29 October 2017. 2017. URL: <https://doi.org/10.1109/iccv.2017.324> (date of access: 08.06.2026).
34. Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks / S. Ren et al. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 2017. Vol. 39, no. 6. P. 1137–1149. URL: <https://doi.org/10.1109/tpami.2016.2577031> (date of access: 08.06.2026).
35. Multi-Class Strawberry Ripeness Detection Dataset. *Kaggle: The World's AI Proving Ground*. URL: <https://www.kaggle.com/datasets/mahyek/multi-class-strawberry-ripeness-detection-dataset> (date of access: 08.06.2026).
36. Bożko A., Ambroziak L. Influence of Insufficient Dataset Augmentation on IoU and Detection Threshold in CNN Training for Object Detection on Aerial Images. *Sensors*. 2022. Vol. 22, no. 23. P. 9080. URL: <https://doi.org/10.3390/s22239080> (date of access: 08.06.2026).
37. Fan C.-L. Evaluation Model for Crack Detection with Deep Learning: Improved Confusion Matrix Based on Linear Features. *Journal of Construction Engineering and Management*. 2025. Vol. 151, no. 3. URL: <https://doi.org/10.1061/jcemd4.coeng-14976> (date of access: 08.06.2026).
38. Advancing Precision, Recall, F-score, and Jaccard Index: An Approach for Continuous, Ratio-scale Measurements / K. Krasnodębska et al. *Environmental Modelling & Software*. 2025. P. 106614. URL: <https://doi.org/10.1016/j.envsoft.2025.106614> (date of access: 08.06.2026).
39. CUDA Toolkit 12.1 Downloads. *NVIDIA Developer*. URL: <https://developer.nvidia.com/cuda-downloads> (date of access: 08.06.2026).

40. Home | Ultralytics Docs. *Ultralytics Docs.*

URL: <https://docs.ultralytics.com/> (date of access: 08.06.2026).

41. Google Colab. *Google Colab.*

URL: <https://colab.research.google.com/> (date of access: 08.06.2026).

42. Gradio. *Gradio.* URL: <https://www.gradio.app/> (date of access: 08.06.2026).

43. Ultralytics/YOLO11 · Hugging Face. *Hugging Face – The AI community building the future.* URL: <https://huggingface.co/Ultralytics/YOLO11> (date of access: 08.06.2026).

# ДОДАТКИ

## Додаток А

### Програмні коди

Вихідний код, використаний у дослідженні, доступний у репозиторії GitHub: <https://github.com/Astrall437/Strawberry-SAHI-Vision> (дата звернення: 14.06.2026).




Рисунок А.1 – Головна сторінка репозиторію

Структура репозиторію наступна:

- `strawberry_sahi_colab.ipynb` — готовий Google Colab notebook із сайтом на Gradio.
- `create_strawberry_sahi_colab.py` — генератор ноутбука, якщо потрібно швидко перебудувати `.ipynb`.
- `weights/strawberry_sahi_yolo11n_best.pt` — локально донавчені стартові ваги YOLO11n.

## Додаток Б

### Презентаційний матеріал

КВАЛІФІКАЦІЙНА РОБОТА БАКАЛАВРА

# МЕТОД НЕЙРОМЕРЕЖЕВОЇ ІДЕНТИФІКАЦІЇ СТАДІЙ ЗРІЛОСТІ ПЛОДІВ ПОЛУНИЦІ ЗА ЗОБРАЖЕННЯМИ ДЛЯ АВТОНОМНИХ ТЕПЛИЧНИХ КОМПЛЕКСІВ



**Виконав:**  
*студент групи КН-22-3*  
**Артур ФІЛІПОВ**



**Керівник:**  
*ст. викл. каф. КН*  
**Тетяна СКРИПНИК**

## Актуальність

Полуниця садова є однією з важливих ягідних культур, а її вирощування в тепличних умовах набуває все більшого поширення завдяки можливості контролювати параметри середовища та підвищувати стабільність урожаю. Одним із ключових етапів виробництва є визначення стадії зрілості плодів, від якого залежать якість продукції, своєчасність збору врожаю та ефективність агротехнічних заходів. Традиційне візуальне оцінювання зрілості є трудомістким і значною мірою залежить від людського фактора.

Сучасні методи комп'ютерного зору та глибокого навчання створюють можливості для автоматизації цього процесу на основі аналізу RGB-зображень. Особливий інтерес становлять нейромережеві детектори, які дозволяють одночасно виявляти плоди та визначати їхню стадію зрілості. Однак застосування таких систем у тепличних умовах ускладнюється перекриттям плодів листям, нерівномірним освітленням, різними масштабами об'єктів і подібністю ознак суміжних стадій дозрівання.

У зв'язку з цим актуальною є задача розроблення методу нейромережевої ідентифікації стадій зрілості плодів полуниці за RGB-зображеннями, здатного забезпечувати надійне виявлення та класифікацію плодів у складних умовах тепличного середовища. Її розв'язання сприятиме підвищенню ефективності агротехнічного моніторингу та автоматизації процесів управління вирощуванням і збором урожаю.

## Мета і задачі роботи

**Об'єкт дослідження** – процес неймережевого виявлення та ідентифікації стадій зрілості плодів полуниці за RGB-зображеннями.

**Предмет дослідження** – методи та засоби глибокого навчання для ідентифікації стадій зрілості плодів полуниці за RGB-зображеннями.

**Мета кваліфікаційної роботи бакалавра** полягає в підвищенні повноти визначення стадій зрілості плодів полуниці за RGB-зображеннями в умовах тепличного середовища.

Для досягнення поставленої мети слід вирішити такі **завдання**:

- провести огляд та аналіз сучасних інформаційних моделей, методів комп'ютерного зору та моделей глибокого навчання для задач виявлення плодів і визначення їхніх стадій зрілості за RGB-зображеннями;
- формалізувати задачу неймережевого виявлення та ідентифікації стадій зрілості плодів полуниці як задачу багатокласової детекції об'єктів у RGB-зображеннях тепличного середовища;
- розробити метод неймережевого виявлення та класифікації плодів полуниці на основі донаведеної YOLO-моделі, орієнтований на підвищення повноти ідентифікації стадій зрілості;
- реалізувати програмний засіб для опрацювання RGB-зображень, навчання моделі, виконання інференсу, візуалізації результатів і формування аналітичної інформації для прийняття рішення щодо збору врожаю;
- провести експериментальне дослідження розробленого методу з оцінюванням якості виявлення та ідентифікації стадій зрілості плодів полуниці.

## Формалізація задачі детекції та класифікації стадій зрілості

Розроблюваний метод реалізує перетворення вхідного зображення тепличної сцени у структуровану множину виявлених плодів із визначеною стадією зрілості кожного з них. Формально вхідним даним відповідає кольорове зображення  $I$  розмірності  $H \times W \times 3$  (висота, ширина та три колірні канали). Метою методу є побудова алгоритмічного оператора  $\Phi$ , який ставить у відповідність зображенню множину виявлених об'єктів  $O$ .

$$\Phi: I \rightarrow O. \quad (1)$$

Кожен виявлений об'єкт описується вектором просторово-семантичного стану, що містить координати геометричного центру обмежувальної рамки, її габарити, ідентифікатор класу та рівень довіри моделі:

$$d = (x, y, w, h, c, p), \quad (2)$$

де  $(x, y)$  – координати центру рамки;  $(w, h)$  – її ширина та висота;  $c$  – клас зрілості (нестигла, напівстигла, стигла);  $p$  – рівень довіри (Confidence Score). Сукупність усіх виявлених на зображенні об'єктів формує множину детекцій:

$$O = \{d_1, d_2, \dots, d_M\}. \quad (3)$$

Оператор  $\Phi$  реалізується неймережею з параметрами (вагами)  $\theta$ , які налаштовуються шляхом мінімізації функціонала втрат  $L$  на навчальній вибірці з еталонними мітками  $Y$ :

$$\theta^* = \arg \min_{\theta} \sum L(\Phi_{\theta}(I), Y). \quad (4)$$

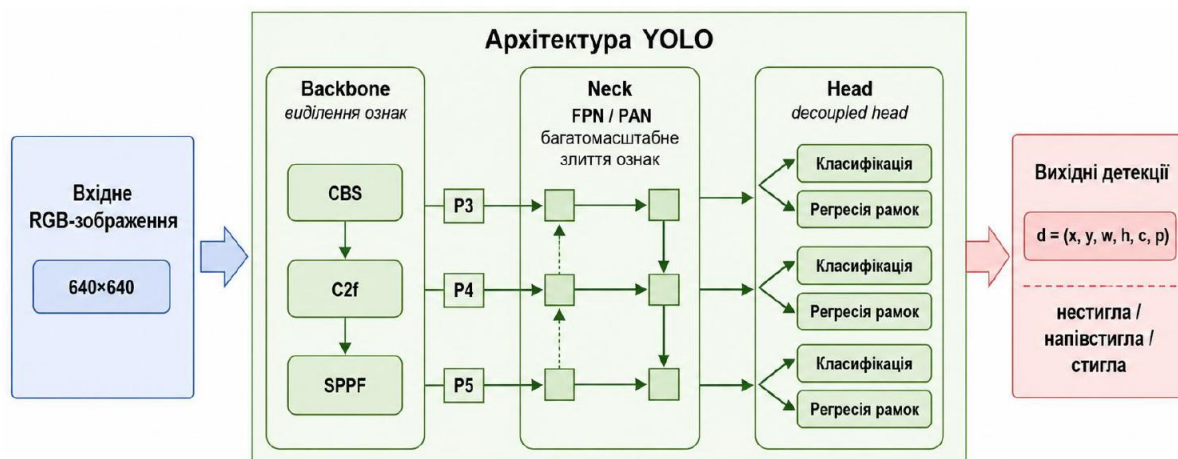
Базовою геометричною мірою якості локалізації та основою як функції втрат, так і метрик оцінювання, є коефіцієнт перекриття площ (Intersection over Union, IoU), який формалізує відношення площі перетину передбаченої рамки  $A$  та еталонної рамки  $B$  до площі їх об'єднання:

$$\text{IoU} = |A \cap B| / |A \cup B|. \quad (5)$$


## Схема методу неймережевої ідентифікації стадій зрілості плодів полуниці




## Архітектура YOLO-детектора для ідентифікації стадій зрілості плодів полуниці



## Схема інференсу для детекції дрібних плодів

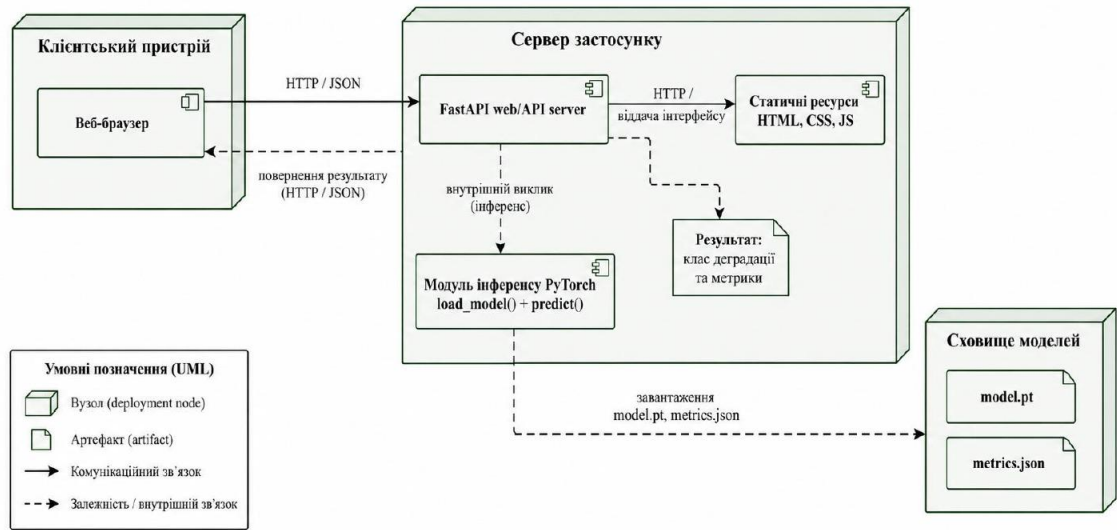


## Опис набору даних та підготовка

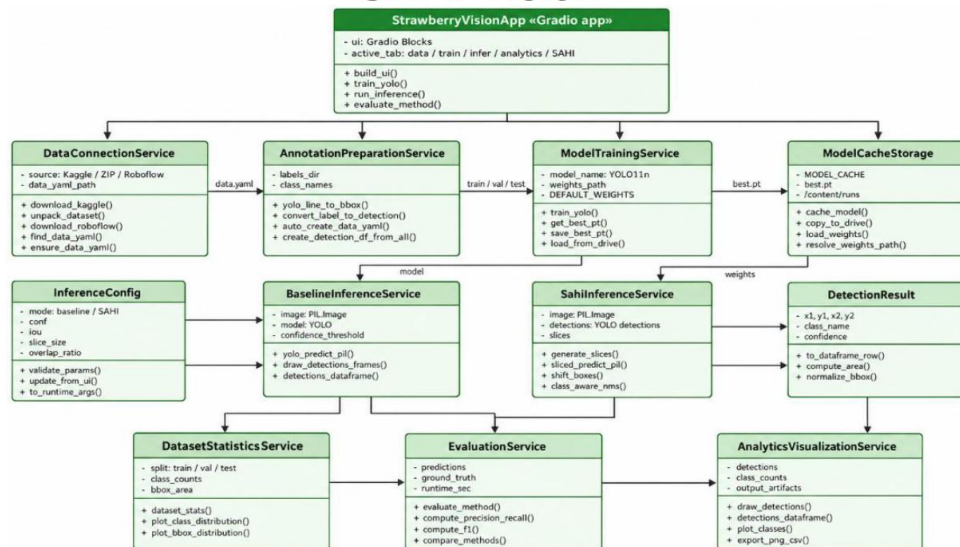


Розподіл зразків по класам у датасеті Multi-Class Strawberry Ripeness Detection Dataset

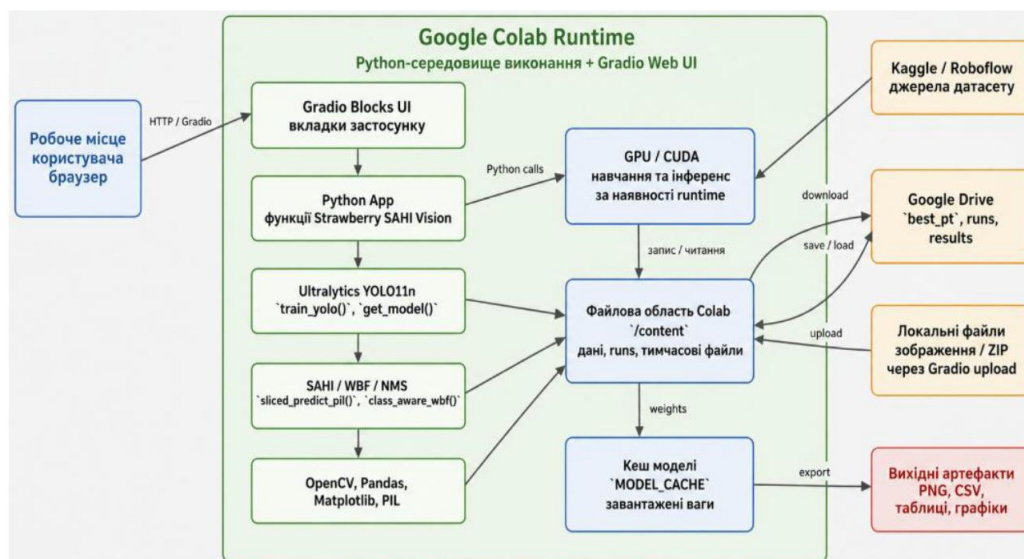
## Діаграма розгортання інтелектуальної системи



## Діаграма логічних класів програмної системи Strawberry SAHI Vision



## Діаграма розгортання програмної системи Strawberry SAHI Vision



## Інтерфейс розробленої системи

The screenshot displays the Strawberry SAHI Vision web interface, divided into two main sections:

**Головна сторінка (Main Page):**

- Strawberry SAHI Vision:** Introduction text describing the system as a Colab-based tool for neural network-based identification of plant diseases using YOLO, fragmentation, and SAHI.
- Tools and Links:** Includes links for YOLO11 / YOLOv8 custom pipeline, SAHI (40-812 ps slices + overlap 0.2), and various datasets like 'kaggle dataset' and 'ZIP з YOLO-даними'.
- Buttons:** 'Завантажити Kaggle dataset' and 'Розпакувати ZIP'.

**Результат SAHI-інференсу на контрольному зображенні (SAHI Inference Results):**

- Parameters:** YOLO images (640, conf: 0.25, YOLO task: 0.5), SAHI slice size (320, SAHI overlap ratio: 0.2, Merge to U: 0.5).
- Image:** A photograph of a plant with red tomatoes, used for testing the detection.
- Bar Chart:** Shows the count of identified classes. The chart has two bars: 'ripe' (blue) with a count of 4, and 'unripe' (red) with a count of 3.


Головна сторінка

Результат SAHI-інференсу на контрольному зображенні

## Аналіз результатів навчання та тестування YOLO-моделі

Підсумкові показники локального навчання YOLO11n      Криві навчання моделі YOLO11n за метриками precision, recall, mAP@50 та mAP@50:95

Показник	Значення
Епохи навчання	4
Precision(B)	0,6348
Recall(B)	0,7151
mAP@50(B)	0,7019
mAP@50:95(B)	0,5267
train/box_loss	1,0607
val/box_loss	0,9896




## Аналіз результатів навчання та тестування YOLO-моделі

Точність моделі YOLO11n на тестовій вибірці за класами


Клас	Зображення	Об'єкти	Precision	Recall	mAP@50	mAP@50:95
all	57	179	0,642	0,669	0,642	0,466
ripe	33	50	0,656	0,740	0,694	0,552
partially_ripe	18	25	0,465	0,661	0,572	0,430
unripe	47	104	0,805	0,606	0,661	0,415

Матриця помилок моделі YOLO11n на тестовій вибірці



## Аналіз результатів навчання та тестування YOLO-моделі

Precision-Recall крива для класів зрілості плодів полуниці



Приклад передбачень моделі YOLO11n на тестових зображеннях



## Обмеження методу та напрямки вдосконалення

### Обмеження дослідження

- залежність точності моделі від якості RGB-зображень (освітлення, тіні, відблиски, фон);
- недостатній обсяг і дисбаланс навчального набору даних;
- складність розпізнавання проміжного класу зрілості (partially\_ripe) через перекриття ознак із сусідніми класами; наявність хибних позитивних і пропущених детекцій у складних тепличних сценах;
- чутливість SAHI-інференсу до параметрів нарізки зображення та постобробки;
- нестабільність експериментальної реалізації через використання Google Colab (обмеження середовища виконання).

### Напрямки вдосконалення

- розширення та балансування датасету, зокрема збільшення прикладів проміжної стадії зрілості;
- додавання складних сцен із фоновими об'єктами (листя, тіні, перекриття);
- оптимізація параметрів YOLO та SAHI з урахуванням Precision, Recall, F1 та швидкості обробки;
- застосування розширених аугментацій і донавчання моделі на складних випадках;
- дослідження альтернативних моделей детекції для малих об'єктів;
- впровадження трекінгу об'єктів у відеопослідовностях для стабілізації результатів;
- перенесення системи з Colab у стабільне середовище розгортання (сервер або edge-пристрій).

## Висновки

У кваліфікаційній роботі бакалавра розв'язано задачу підвищення повноти визначення стадій зрілості плодів полуниці за RGB-зображеннями в умовах тепличного середовища шляхом розроблення методу нейромережевої ідентифікації стадій зрілості плодів полуниці за зображеннями на основі донавченої YOLO-моделі, що забезпечує автоматичну локалізацію плодів, визначення їхньої стадії зрілості та формування аналітичної інформації для прийняття рішення щодо збору врожаю.

Мету досягнуто повністю, а для її досягнення було вирішено такі завдання:

- проведено огляд та аналіз сучасних інформаційних моделей, методів комп'ютерного зору та моделей глибокого навчання для задач виявлення плодів і визначення їхніх стадій зрілості за RGB-зображеннями;
- формалізовано задачу нейромережевого виявлення та ідентифікації стадій зрілості плодів полуниці як задачу багатокласової детекції об'єктів у RGB-зображеннях тепличного середовища;
- розроблено метод нейромережевого виявлення та класифікації плодів полуниці на основі донавченої YOLO-моделі, орієнтований на підвищення повноти ідентифікації стадій зрілості;
- реалізовано програмний засіб для опрацювання RGB-зображень, навчання моделі, виконання інференсу, візуалізації результатів і формування аналітичної інформації для прийняття рішення щодо збору врожаю;
- проведено експериментальне дослідження розробленого методу з оцінюванням якості виявлення та ідентифікації стадій зрілості плодів полуниці.

ДЯКУЮ ЗА УВАГУ!

---

## Протокол аналізу звіту подібності науковим керівником

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

**Автор:** Артур ФІЛПОВ

**Співавтор:**

**Назва:** КВАЛІФІКАЦІЙНА РОБОТА БАКАЛАВРА на тему Метод нейромережевої ідентифікації стадій зрілості плодів полуниці за зображеннями для автономних тепличних комплексів

**Науковий керівник:** Тетяна СКРИПНИК, ст.викл. каф. КН

**Підрозділ:** Кафедра комп'ютерних наук

**Коефіцієнт подібності 1:** 6.54%

**Коефіцієнт подібності 2:** 2.51%

**Мікропробіли:** 0

**Заміна букв:** 7

**Інтервали:** 0

**Білі знаки:** 5

**Дата створення звіту:** 2026-06-17 10:49:15.0

Після аналізу Звіту подібності констатую наступне:

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

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

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

Обґрунтування:

2026-06-17

Дата

експерт

*Литовський Р.Р.*



Wed Jun 17 12:35:51 EEST 2026, Петровський Сергій Степанович, Хмельницький національний університет, ХНУ

## Anti-Plagiarism (http://ap.km.ua) v-16.718

**Максимальне співпадіння з одним документом 3.0%**

**Словники перевірки: UA, US, RU. Помилки в документах: 15%**

ID: 275732 Назва: КВАЛІФІКАЦІЙНА РОБОТА БАКАЛАВРА на тему Метод нейромережевої ідентифікації стадій зрілості плодів полуниці за зображеннями для автономних тепличних комплексів Додано в БД: 2026-06-17 Автора: Артур ФІЛПОВ Керівники: Тетяна СКРИПНИК Консультанти: Опоненти:	Документ		Сумарний збіг по Базі Даних	
	Символи	Лексеми	Символи	Лексеми
	84483	645	4055 (5%)	54 (8%)

### Джерело плагіату

ID	Опис	Наявність плагіату в документі	
		Символи	Лексеми

# РІШЕННЯ ЕКСПЕРТНОЇ КОМІСІЇ КАФЕДРИ КОМП'ЮТЕРНИХ НАУК

## ПРО ДОПУСК КВАЛІФІКАЦІЙНОЇ РОБОТИ ДО ЗАХИСТУ

Назва кваліфікаційної роботи Метод нейромережевої ідентифікації стадій зрілості плодів полуниці за зображеннями для автономних тепличних комплексів

Автор студент групи КН-21- 3 Філіпов Артур Арсенійович

Освітня програма Комп'ютерні науки

Рівень вищої освіти перший (бакалаврський)

Спеціальність 122 – Комп'ютерні науки

Науковий керівник: старший викладач кафедри комп'ютерних наук Тетяна Скрипник

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

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

Підтвердження:

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

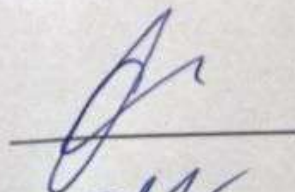
*Обсяг запозичень, визначений системами виявлення збігів/ідентичності/схожості:*

- за системою *Anti-Plagiarism*: 3%;

- за системою *StrikePlagiarism* КП1: 6.54%, КП2: 2.51%.

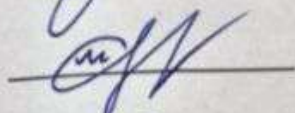
18.06.2026

Завідувач кафедри



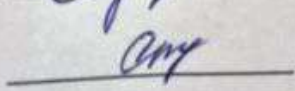
Олександр БАРМАК

Гарант освітньої програми



Олександр МАЗУРЕЦЬ

Керівник кваліфікаційної роботи



Тетяна СКРИПНИК



**ВІДГУК НАУКОВОГО КЕРІВНИКА  
на кваліфікаційну роботу бакалавра**

студента КН-21-3 Філіпов Артур Арсенійович  
за темою Метод нейромережевої ідентифікації стадій зрілості плодів полуниці за зображеннями для автономних тепличних комплексів

**1. Актуальність теми**

Автоматизація процесів контролю якості сільськогосподарської продукції є одним із важливих напрямів розвитку сучасних інформаційних технологій. Використання нейромережевих методів для визначення стадій зрілості плодів полуниці за зображеннями сприяє підвищенню ефективності роботи автономних тепличних комплексів та зменшенню витрат на моніторинг урожаю.

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

Робота присвячена розробленню методу аналізу цифрових зображень із застосуванням технологій глибокого навчання та повністю відповідає предметній області спеціальності 122 Комп'ютерні науки.

**3. Професійні та особистісні якості бакалавра**

Під час виконання кваліфікаційної роботи студент Філіпов Артур Арсенійович проявив себе відповідальним, дисциплінованим та наполегливим здобувачем освіти, здатним самостійно вирішувати поставлені завдання.

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

Усі етапи роботи, починаючи з аналізу предметної області та закінчуючи програмною реалізацією методу, виконані студентом самостійно.

**5. Ступінь оволодіння методами дослідження**

Студент продемонстрував належний рівень володіння методами машинного та глибокого навчання, засобами оброблення зображень і сучасними технологіями розроблення програмного забезпечення.

**6. Повнота та якість розкриття теми роботи**

Тема роботи розкрита повністю. Проведено аналіз сучасних підходів до класифікації зображень, розроблено метод нейромережевої ідентифікації стадій зрілості плодів полуниці та здійснено його програмну реалізацію.

7. Логічність, послідовність, аргументованість, літературна грамотність викладення матеріалу

Матеріал роботи викладено логічно, послідовно та відповідно до вимог академічного тисьма.

8. Можливість практичного застосування кваліфікаційної роботи бакалавра, окремих її частин

Розроблений метод може бути використаний у системах автоматизованого контролю стану плодів та управління автономними тепличними комплексами.

9. Висновок про можливість допуску кваліфікаційної роботи бакалавра до захисту, на яку оцінку заслуговує робота

Кваліфікаційна робота бакалавра Філіпова Артура Арсенійовича виконана на належному рівні, відповідає встановленим вимогам та може бути допущена до захисту. Рекомендована оцінка – «добре».

Керівник \_\_\_\_\_



старший викладач каф. КН Тетяна СКРИПНИК



## РЕЦЕНЗІЯ

### на кваліфікаційну роботу бакалавра

студента КН-22-3 Філіпов Артур Арсенійович

за темою: Метод нейромережевої ідентифікації стадій зрілості плодів полуниці за зображеннями для автономних тепличних комплексів

#### 1. Актуальність обраної теми

Тематика кваліфікаційної роботи відповідає сучасним напрямкам розвитку штучного інтелекту, комп'ютерного зору та технологій точного землеробства. Автоматизація процесів вирощування сільськогосподарських культур є одним із пріоритетних напрямів розвитку сучасних автономних тепличних комплексів. Однією з актуальних задач є своєчасне та точне визначення стадій зрілості плодів, що дозволяє оптимізувати процеси збирання врожаю, підвищити продуктивність і зменшити витрати людських ресурсів. Використання методів глибокого навчання та аналізу цифрових зображень для ідентифікації ступеня зрілості плодів полуниці визначає актуальність і практичну значущість проведеного дослідження.

#### 2. Повнота розкриття мети та завдань роботи

Автором кваліфікаційної роботи бакалавра повністю розкрито поставлену мету та виконано визначені завдання. У роботі проведено аналіз предметної області, досліджено сучасні методи комп'ютерного зору та нейромережеві підходи до класифікації зображень, спроектовано та реалізовано метод нейромережевої ідентифікації стадій зрілості плодів полуниці за зображеннями, а також виконано дослідження ефективності запропонованого методу.

#### 3. Зміст кожного розділу роботи

У першому розділі кваліфікаційної роботи проаналізовано предметну область, особливості вирощування полуниці в автономних тепличних комплексах, сучасні підходи до аналізу цифрових зображень та застосування методів глибокого навчання, а також сформульовано мету і завдання дослідження. У другому розділі наведено опис розробленого методу, алгоритмів обробки зображень та побудови нейромережевої моделі, а також деталізовано проектування програмної реалізації. У третьому розділі представлено програмну реалізацію методу та результати експериментального дослідження щодо оцінювання ефективності запропонованого підходу.

#### 4. Оцінка розробленого методу та його практична цінність

Розроблений метод дозволяє автоматизувати процес ідентифікації стадій зрілості плодів полуниці за цифровими зображеннями та може бути використаний в автономних тепличних комплексах, роботизованих системах збирання врожаю та інтелектуальних системах моніторингу стану сільськогосподарських культур.

#### 5. Якість оформлення кваліфікаційної роботи бакалавра

Кваліфікаційна робота бакалавра виконана на високому рівні. Матеріал викладено логічно, послідовно та структуровано. Наведені таблиці, рисунки, схеми та графіки сприяють кращому сприйняттю результатів дослідження та підтверджують обґрунтованість зроблених висновків.

6. Недоліки кваліфікаційної роботи бакалавра

Суттєві недоліки у кваліфікаційній роботі відсутні. Як побажання, можна рекомендувати розширити експериментальні дослідження шляхом використання більшої кількості зображень, отриманих за різних умов освітлення та на різних етапах вирощування культури, а також провести порівняльний аналіз із додатковими сучасними архітектурами нейронних мереж. Проте зазначені зауваження не знижують наукової та практичної цінності отриманих результатів.

7. Загальний висновок (допускається чи не допускається до захисту), та оцінка на яку заслуговує кваліфікаційна робота.

З огляду на високий рівень виконання та відповідність установленим вимогам, кваліфікаційна робота бакалавра Філіпова Артура Арсенійовича може бути допущена до захисту. Рекомендована оцінка – «добре».

Рецензент к.ф.-м.н., доц. Радський А.О.

